

Universidad Pública de Navarra

**ESCUELA TÉCNICA SUPERIOR
DE INGENIEROS AGRÓNOMOS**

Nafarroako Unibertsitate Publikoa

***NEKAZARITZAKO INGENIARIEN
GOI MAILAKO ESKOLA TEKNIKOA***

EVALUACIÓN DE LA CALIDAD DE LA PATATA MEDIANTE TECNOLOGÍA NIRS

Presentado por

Raquel Pérez García

Aurkeztua

Directoras

Ainara López Maestresalas

y

Claudia Pérez Roncal

**MÁSTER UNIVERSITARIO EN TECNOLOGÍA Y CALIDAD EN LAS INDUSTRIAS
AGROALIMENTARIAS**

***UNIBERTSITATE MASTERRA NEKAZARITZAKO ELIKAGAIEN INDUSTRIETAKO TEKNOLOGIAN
ETA KALITATEAN***

Septiembre, 2018

Índice

Índice de Figuras	3
Índice de Tablas.....	4
0. Resumen – palabras clave / Abstract – key words.....	5
1. Introducción y objetivo	6
2. Revisión bibliográfica	7
2.1. Cultivo de la patata	7
2.1.1. La patata.....	7
2.1.2. Origen y evolución del cultivo de la patata.....	7
2.1.3. Importancia del cultivo de la patata	8
2.1.3.1. Importancia del cultivo de patata a nivel mundial.....	8
2.1.3.2. Importancia del cultivo de patata en España.....	11
2.2. Parámetros de calidad de la patata	14
2.2.1. Propiedades reológicas: Textura	14
2.2.2. Propiedades ópticas: Color	16
2.3. Tecnología NIRS.....	17
2.3.1. Bases teóricas.....	17
2.3.2. Instrumentación	18
2.3.3. Quimiometría	21
2.3.3.1. Análisis cuantitativo	21
2.3.3.2. Análisis cualitativo	24
2.3.4. Aplicaciones NIRS en la evaluación de la textura en patata	24
3. Material y métodos	25
3.1. Diseño experimental	25
3.2. Material vegetal	27
3.3. Instrumentación	28
3.3.1. Balanza	28
3.3.2. Espectrofotómetro	28
3.3.3. Texturómetro	28
3.3.4. Equipo NIRS.....	30
3.4. Análisis quimiométrico: Desarrollo del modelo.....	31
3.4.1. Regresión PLS	31
3.4.2. PLS-DA	32

3.5.	Análisis estadístico	34
3.5.1.	ANOVA.....	34
4.	Resultados y discusión	34
4.1.	Parámetros de calidad.....	34
4.1.1.	Peso	34
4.1.1.	Color	36
4.1.2.	Textura	38
4.2.	Análisis quimiométrico.....	39
4.2.1.	Modelo de predicción. Regresión PLS.....	41
4.2.2.	Modelo de clasificación. PLS-DA	45
5.	Conclusiones.....	47
6.	Bibliografía	49

Índice de Figuras

Figura 1. Principales cultivos alimentarios mundiales: producción en millones de t, área cosechada en millones de ha y rendimiento en t/ha. (Elaboración propia. Fuente: FAO (2016a)).	8
Figura 2. Evolución de la producción de patatas en los diferentes regiones en millones de t. (Elaboración propia. Fuente: FAO (2016b)).	9
Figura 3. (a) Producción de patata por regiones en 2016 y (b) Consumo en 2013. (Elaboración propia. Fuente: FAO (2016a) y FAO (2013a)).	9
Figura 4. Principales países productores de patata: producción en millones de t y rendimiento en t/ha. (Elaboración propia. Fuente: FAO (2016b)).	10
Figura 5. Evolución de la población (millón personas), Consumo (kg/persona), producción (100 mil t), área cultivada (10 mil ha) y rendimiento (t/ha). (Elaboración propia. Fuente: FAO, 2016b)	12
Figura 6. Evolución del suministro interno de patata (mil t), exportación (mil t) e importación (mil t). (Elaboración propia. Fuente: FAO, 2013b)	12
Figura 7. Histórico de precios medios nacionales de patatas (€/100 kg) a lo largo de las diferentes semanas del año. (Elaboración propia. Fuente: MAGRAMA, 2018)	14
Figura 8. Espacio CIELab (Konika Minolta, 2014)	16
Figura 9. Espectro electromagnético (López-Maestresalas, 2016)	17
Figura 10. Modos de medición NIRS: (a) reflectancia, (b) transmitancia, (c) transreflectancia e (e) interactancia (Elaboración propia).	18
Figura 11. Esquema del diseño experimental	26
Figura 12. Espectrofotómetro Konika Minolta, modelo CM-2500d (Konika Minolta, 2014)	28
Figura 13. Texturómetro TA-XT2Plus de <i>Stabla Micro Systems</i> durante ensayo de punción.	29
Figura 14. Curva Fuerza-deformación (N/mm) obtenida del ensayo de punción de los tubérculos	29
Figura 15. Espectrofotómetro Brimrose Luminar 5030	30
Figura 16. Evolución del peso (g) de las patatas del grupo experimental a lo largo de los diferentes días de almacenamiento. Las letras indican si existen diferencias significativas ($p < 0,05$) entre los distintos días de almacenamiento.	35
Figura 17. Evolución de los parámetros de color a^* , b^* y L^* de las patatas a lo largo de los distintos días de almacenamiento. Las letras indican si existen diferencias significativas ($p < 0,05$) entre las muestras para cada parámetro analizado.	36
Figura 18. Representación gráfica de la fuerza máxima (N) y la pendiente de la curva fuerza-deformación registradas durante los diferentes días de almacenamiento	38
Figura 19. Representación gráfica de la fuerza máxima (N) y la pendiente de la curva fuerza-deformación registradas durante los diferentes días de almacenamiento	39
Figura 20. Espectros de reflectancia de las patatas analizadas en el rango de 1100 a 2300 nm.	39
Figura 21. Espectros de reflectancia NIR tras aplicar pretratamientos: (a) MSC, (b) MSC + 1^a derivada, (c) SNV, (d) SNV + 1^a derivada, (e) SNV + Detrend	40
Figura 22. Recta de validación externa del modelo de predicción de la variable fuerza de rotura de piel para los datos pretratados con SNV.	42
Figura 23. Coeficientes de regresión del modelo PLS para la predicción de la fuerza de rotura de la piel de la patata con los pretratamientos SNV mostrando las variables más influyentes en la elaboración del modelo.	43

Figura 24. Recta de validación externa del modelo de predicción de la variable fuerza de rotura de piel para los datos pretratados con MSC.	43
Figura 25. Coeficientes de regresión del modelo PLS para la predicción de la fuerza de rotura de la piel de la patata con los pretratamientos SNV mostrando las variables más influyentes en la elaboración del modelo.	44
Figura 26. Resultados del modelo PLS-DA para los grupos 1, 2, 3 y 4. Estimación para el grupo 2.	46

Índice de Tablas

Tabla 1. Clasificación de países con mayor tasa de consumo total (t/año) y consumo por persona (kg/persona/año). (Elaboración propia. Fuente: FAO (2013a)).	11
Tabla 2. Análisis provincial de producción (t), superficie (ha) y rendimiento (t/ha)(MAGRAMA, 2016).	13
Tabla 3. Variedades de patata estudiadas donde se indica el color de piel y carne (Am: amarilla, Bl: blanco, Ro: roja, y Vi: violeta), textura (F: firme, H: harinosa) y madurez (Temprana, Semitemprana, Semitardía, Tardía e Indefinida) (Origen: NEIKER Arkaute, Álava)	27
Tabla 4. Peso medio (g) de cada variedad de patata del grupo experimental con su desviación estándar. Las letras indican si existen diferencias significativas ($p < 0,05$) de peso entre cada variedad.	35
Tabla 5. Diferencias de los parámetros de color L^* , a^* y b^* y diferencia de color total (ΔE) entre el inicio y final del almacenamiento.	37
Tabla 6. Resultados de la validación cruzada y la predicción de los parámetros fuerza de rotura de la piel (N), fuerza máxima (N) y sus respectivas pendientes de las curvas de carga (N/mm) para los tubérculos de patata.	41
Tabla 7. Resultados de los modelos PLS-DA desarrollados.	45
Tabla 8. Matriz de confusión para el modelo PLS-DA con pretratamiento SNV+DT.	46
Tabla 9. Sensibilidad y Especificidad para los diferentes grupos.	47

0. Resumen

La industria alimentaria se enfrenta al reto de ofrecer productos de calidad. Este trabajo analiza la viabilidad de la tecnología NIRS como herramienta para predecir la textura y clasificar los tubérculos según esta. Además de estudiar las variaciones de peso y color que ocurren durante el almacenamiento de diferentes variedades de patata. Tras 72 días, la pérdida de peso se situó en torno al 2,16%. Todas fueron oscureciéndose y la firmeza también fue reduciéndose en este periodo. El modelo de regresión PLS para la predicción de la textura a través de la fuerza de rotura de la piel obtuvo una R^2_p de 0,54. El modelo PLS-DA clasificó correctamente 76,39% de los tubérculos analizados. Por tanto, aunque los modelos desarrollados pueden discriminar entre valores altos y bajos del parámetro evaluado, no son lo suficientemente fiables, por lo que surge la necesidad de continuar investigando para obtener modelos robustos que permitan garantizar la calidad de las patatas.

Palabras clave. NIRS, PLS, PLS-DA, textura, color, pérdida peso, patata, calidad.

0. Abstract

The food industry faces the challenge of offering quality products. This work analyses the viability of NIRS technology as a tool to predict texture and classify tubers according to it. It also studies the weight and colour variations that occur during the storage of different potato varieties. After 72 days, the weight loss was around 2.16%. All of them became darker and firmness also decreased in this period. The PLS regression model for predicting texture through skin breaking strength obtained an R^2_p of 0.54. The PLS-DA model correctly classified 76.39% of the analysed tubers. Therefore, although the models developed may discriminate between high and low values of the parameter evaluated, they are not reliable enough, so there is a need to continue research to obtain robust models to guarantee the quality of the potatoes.

Key words. NIRS, PLS, PLS-DA, texture, color, weight loss, potato, quality.

1. Introducción y objetivo

La patata (*Solanum tuberosum* L.) es uno de los cultivos alimentarios que mayor producción y consumo presenta a nivel mundial, tras la caña de azúcar, el maíz, el trigo y el arroz (FAO, 2016). En los últimos años, su producción ha experimentado un crecimiento mucho mayor que la de otros tubérculos y principalmente en países en desarrollo, debido a su alto rendimiento y valor nutritivo (Shing y Kaur, 2009). De este modo, la patata puede considerarse un cultivo básico y necesario para satisfacer el aumento de la demanda de alimento, generada por el incesante crecimiento de la población mundial (Birch *et al.*, 2012). Además, la patata es un alimento muy versátil y popular, ya que puede ser consumida de diversas maneras: cocida, frita, deshidratada o como ingrediente de alimentos procesados industrialmente (Jarén *et al.*, 2016). El tamaño, el aspecto general, el color y la textura son los principales parámetros de calidad que condicionan su aceptabilidad dentro del mercado (Shing y Kaur, 2009). La textura tradicionalmente se ha evaluado mediante análisis sensoriales o instrumentales, que son destructivos, costosos y requieren mucho tiempo para su realización.

Actualmente la industria alimentaria se enfrenta al reto de satisfacer la demanda de productos de mayor calidad y de cumplir los requisitos impuestos por los organismos de control en temas de seguridad alimentaria y trazabilidad (Grassi y Alamprese, 2018). Para hacer frente a estos desafíos, la industria agroalimentaria tiende a adoptar un enfoque predictivo, basado en el ajuste del proceso en tiempo real durante la elaboración del producto. Este tipo de medidas además, reducen costes de producción y aumentan la eficiencia energética (Grassi y Alamprese, 2018). Berg *et al.* (2013) consideran este tipo de enfoque como “una revolución silenciosa en la calidad industrial”. Según Jarén *et al.* (2016) el desarrollo de áreas tecnológicas como la informática, los dispositivos ópticos, y la miniaturización, combinado con un descenso considerable de los precios, han hecho posible mejoras reales en este campo. Dentro de estas tecnologías avanzadas, se encuentra la espectroscopia de infrarrojo cercano (NIRS), que ha demostrado ser una alternativa factible a los métodos analíticos comúnmente empleados, ya que es una técnica rápida, no destructiva, rentable y respetuosa con el medio ambiente (López- Maestresalas, 2016).

Por todo ello, este trabajo tiene como objetivo estudiar la viabilidad de la tecnología NIRS como herramienta para determinar la calidad de las patatas crudas. Para lograr este cometido, se pretende evaluar la capacidad para predecir la textura y clasificar las patatas según sus espectros NIR. Además de estudiar las variaciones de peso y color que ocurren a lo largo del almacenamiento de diferentes variedades de patata.

2. Revisión bibliográfica

2.1. Cultivo de la patata

2.1.1. La patata

Solanum tuberosum L. es una planta herbácea perenne que produce tubérculos para llevar a cabo su propagación vegetativa. Los tubérculos, comúnmente llamados patatas o papas, son protuberancias del tallo subterráneo, también denominados rizoma o estolón subterráneo (Burton, 1989).

Las patatas constituyen el principal órgano de almacenamiento de la planta y actualmente, en el mercado están disponibles un gran número de variedades, con formas, tamaños, colores y texturas muy diversas.

Los tubérculos crudos recién cosechados contienen aproximadamente un 80% de agua y un 20% de materia seca. El almidón es el compuesto mayoritario ya que llega a constituir el 60 u 80% de la materia seca. Además, este hidrato de carbono aporta altos niveles de energía. En base seca, el contenido de proteínas de la patata es similar al de los cereales y es muy elevado en comparación con otros tubérculos. También son ricos en calcio, potasio y vitamina C y tienen un equilibrio de aminoácidos especialmente bueno (Jarén *et al.*, 2016).

2.1.2. Origen y evolución del cultivo de la patata

En la actualidad las patatas cultivadas pertenecen a diferentes variedades de la especie *Solanum tuberosum* L. Estas son el resultado de miles de años de evolución donde se han producido múltiples hibridaciones entre diferentes especies de plantas de la familia de las *solanáceas*. Aunque su origen ha sido motivo de controversia, se ha demostrado genéticamente que las primeras patatas fueron cultivadas hace unos 6.000 - 10.000 años en la cordillera de los Andes, concretamente en las cercanías del lago Titicaca (Bradshaw y Ramsay, 2009). Posteriormente se extendieron por todo Latino América y tras la llegada de Colón en 1492 se difundieron por Europa y finalmente al resto del mundo.

Durante los últimos 150 años, los agricultores han tratado de desarrollar cultivares de patata de madurez más temprana, tubérculos más lisos, más resistentes a enfermedades y de mejor calidad desde el punto de vista del procesamiento, realizando hibridaciones entre diferentes variedades (Shing y Kaur, 2009). Recientemente, con el desarrollo de la ingeniería genética, se han desarrollado además una gran variedad de patatas modificadas genéticamente. Sin embargo, estas variedades transgénicas no están permitidas en muchos países o su uso está

cuestionado, debido a preocupaciones relacionadas con la seguridad del consumidor y del medio ambiente (Qu *et al.*, 2015).

2.1.3. Importancia del cultivo de la patata

2.1.3.1. Importancia del cultivo de patata a nivel mundial

Las patatas gozan de una gran popularidad debido a su alto rendimiento, calidad nutricional y amplia gama de usos culinarios. Su producción está ampliamente distribuida en más de 160 países y su superficie de cultivo alcanza los 19 millones de hectáreas (FAO, 2016a). Además, se estima que proporciona alimento a más de mil millones de personas (Tanios *et al.*, 2018). Se sitúa entre los cultivos más importantes a nivel mundial tras la caña de azúcar, el maíz, el trigo y el arroz, llegando a superar los 376 millones de toneladas de producción (FAO, 2016a). La patata destaca por su facilidad de cultivo y alto rendimiento, siendo superado únicamente por el elevadísimo rendimiento de la caña de azúcar (Figura 1). Puede considerarse como un sustituto de la cosecha de cereales debido a que supera sus rendimientos y son de gran valor nutritivo (Zhang *et al.*, 2017).




Figura 1. Principales cultivos alimentarios mundiales: producción en millones de t, área cosechada en millones de ha y rendimiento en t/ha. (Elaboración propia. Fuente: FAO (2016a)).

Otro aspecto importante a tener en cuenta es el incremento de la demanda de alimentos debido al crecimiento continuo de la población mundial. En 2017 se superaron los 7500 millones de personas y se prevé que se alcancen los 9000 millones en 2050 (Naciones Unidas, 2017). Este crecimiento incesante de la población junto con la incertidumbre que genera el cambio climático, hacen que sea fundamental evaluar la situación mundial del cultivo de la patata en el contexto de la seguridad alimentaria. Según la FAO, existe seguridad alimentaria "cuando todas las personas en todo momento tienen acceso a suficientes alimentos inocuos y nutritivos para mantener una vida sana y activa".




Figura 2. Evolución de la producción de patatas en los diferentes regiones en millones de t. (Elaboración propia. Fuente: FAO (2016b)).

Como se puede observar en la Figura 2, hace 50 años prácticamente la totalidad de las patatas producidas procedían de Europa y en menor medida de América del Norte y países de la antigua Unión Soviética. Sin embargo, mientras sus producciones han ido reduciéndose progresivamente, en regiones como Asia, África y América Latina ha habido un crecimiento espectacular, llegando en 2005 a superar la producción europea. El incremento de los precios mundiales de los alimentos y principalmente de los cereales, que amenazaban la seguridad alimentaria y la estabilidad de países de bajos ingresos, pudo ser en parte el motivo del aumento de interés por el tubérculo de patata (Lutaladio y Castaldi, 2009).




Figura 3. (a) Producción de patata por regiones en 2016 y (b) Consumo en 2013. (Elaboración propia. Fuente: FAO (2016a) y FAO (2013a)).

Actualmente, entre los principales productores de patata destacan Asia, que engloba el 50,6% de la producción mundial, le sigue Europa con un 31,2% y América con un 11,3%. Muy por detrás se encuentran África y Oceanía con un 6,5% y 0,4% respectivamente (Figura 3a).




Figura 4. Principales países productores de patata: producción en millones de t y rendimiento en t/ha. (Elaboración propia. Fuente: FAO (2016b))

El cultivo de patata en China supera los 99 millones de toneladas anuales, lo que supone más de un 25% de la producción mundial. De este modo, se ha convertido en el primer país productor de patata, duplicando la producción de India y triplicando la de la Federación de Rusia (Figura 4). Cabe destacar que aunque en los últimos 60 años la superficie destinada al cultivo de patata en todo el mundo se ha mantenido prácticamente constante, su producción ha ido en aumento debido a la notoria mejoría de los rendimientos. Sin embargo, se observan grandes diferencias entre países. Mientras que China e India no superan las 20 toneladas por hectárea, los rendimientos en EEUU y países europeos como Alemania, Francia y Países Bajos, superan las 40 toneladas por hectárea. Este aumento de productividad se debe a la utilización de variedades de patata mejoradas que poseen un mayor potencial de rendimiento y resistencia a plagas y enfermedades, así como al uso de patatas de siembra de calidad, y al mejor manejo de plagas y enfermedades (Lutaladio y Castaldi, 2009). Las condiciones climatológicas que se desarrollan durante la campaña también pueden condicionar estos rendimientos.

El continente asiático también se encuentra a la cabeza en cuanto al consumo de patata se refiere, ya que engloba el 51,7% del consumo mundial. Le sigue Europa con un 25,6% y América con un 14%. Aunque la producción y consumo en África están aumentando, actualmente supone un 8% respecto al total y Oceanía únicamente un 0,7% (Figura 3b).

Tabla 1. Clasificación de países con mayor tasa de consumo total (t/año) y consumo por persona (kg/persona/año). (Elaboración propia. Fuente: FAO (2013a)).

		Consumo (t)			Consumo (kg/persona)
1.	 China	57 732 459	1.	 Belarús	183,16
2.	 India	30 546 470	2.	 Ucrania	135,94
3.	 EEUU	16 605 733	3.	 Malawi	131,69
4.	 Fed. de Rusia	16 177 946	4.	 Montenegro	119,31
5.	 Bangladesh	7 266 350	5.	 Letonia	116,52
6.	 Reino Unido	6 583 286	6.	 Fed. de Rusia	113,26
7.	 Ucrania	6 149 758	7.	 Kazajstán	111,34
8.	 Alemania	5 084 154	8.	 Polonia	104,00
9.	 Polonia	3 974 397	9.	 Reino Unido	103,86
10.	 Irán (Rep. Islámica)	3 921 810	10.	 Rwanda	99,61
Consumo mundial		296 807 035	Consumo medio mundial		34,9

En la tabla 1 se observa como los mayores consumos de patata se registran en los países más poblados del planeta. China se posiciona en primer lugar, debido a la incorporación de la patata en su gastronomía. Le sigue India y EEUU. Sin embargo, son los países europeos los que mayor consumo per cápita presentan, llegando a alcanzar los 183 kg por persona en Belarús.

2.1.3.2. Importancia del cultivo de patata en España

Con una población que supera los 46 millones de habitantes, España ocupa el puesto 15º a nivel mundial en cuanto al consumo total de patata, con 2,3 millones de toneladas anuales. También se encuentra dentro de los 35 países con mayor producción, alcanzando los 2 millones de toneladas (FAO, 2016). Sin embargo, se puede observar en la Figura 5 como la patata ha gozado de mayor popularidad en tiempos pasados. Fue a partir de 1990 cuando el cultivo de la patata comenzó a disminuir, siguiendo la misma tendencia que en el resto de países europeos. De este modo, su producción ha llegado a reducirse hasta día de hoy un 40% y su consumo un 66%. Según Señán (2010) una disminución en la demanda de alimentos como la patata es una práctica habitual en países desarrollados, ya que cuando se tiene asegurado el consumo de alimentos básicos, la tendencia es la de adquirir productos menos esenciales en la cadena alimenticia. Además, los nuevos estilos de vida caracterizados por la falta de tiempo para cocinar, también pueden propiciar estos cambios en los hábitos de consumo (Escuredo *et al.*, 2018).




Figura 5. Evolución de la población (millón personas), Consumo (kg/persona), producción (100 mil t), área cultivada (10 mil ha) y rendimiento (t/ha). (Elaboración propia. Fuente: FAO, 2016b)

Del mismo modo, la superficie destinada al cultivo de la patata ha experimentado un notorio descenso, pasando de las 270 mil hectáreas a comienzos de la década de los 90 a las 64 mil hectáreas actuales (FAO, 2016). Esto ha supuesto una reducción de más del 75%, aunque se ha visto compensado con el aumento del rendimiento de producción, que ha llegado a triplicarse, alcanzando las 32,7 t/ha (FAO, 2016).




Figura 6. Evolución del suministro interno de patata (mil t), exportación (mil t) e importación (mil t). (Elaboración propia. Fuente: FAO, 2013b)

En la Figura 6 puede observarse como hasta finales de 1980 el suministro interno de patata dependía principalmente de la producción propia. Sin embargo, a partir de 1985 comenzó a producirse una disminución de la producción interna y de manera simultánea un aumento en la cantidad de patatas importadas, llegando a suponer en 2013 hasta prácticamente la mitad de las patatas consumidas en el país.

Las comunidades autónomas que mayor extensión de terreno dedicaron al cultivo de patata en 2016 fueron Castilla y León, Galicia, Andalucía y Valencia. Además, solamente sus producciones cubrieron más del 82% de la producción total (MAGRAMA, 2016). Llama la

atención la gran variabilidad de rendimientos que existe entre comunidades, ya que mientras Canarias solamente alcanza las 22,08 t/ha, La Rioja supera las 46 t/ha (Tabla 2). Estas diferencias pueden deberse entre otros motivos, al tipo modelo productivo empleado.

Tabla 2. Análisis provincial de producción (t), superficie (ha) y rendimiento (t/ha)(MAGRAMA, 2016).

Comunidad autónoma	Producción (t)	Superficie (ha)	Rendimiento (t/ha)
Castilla y León	853 914	19 874	42,97
Galicia	417 081	19 054	21,89
Andalucía	316 500	11 904	26,59
Murcia	193 721	5 178	37,41
Canarias	115 173	5 216	22,08
C. Valenciana	84 016	3 073	27,34
Castilla La Mancha	66 025	2 264	29,16
Baleares	58 547	1 743	33,59
País Vasco	56 241	1 557	36,12
La Rioja	56 074	1 217	46,08
Cataluña	21 852	969	22,55
Extremadura	20 430	844	24,21
Aragón	16 237	553	29,36
Asturias	12 660	513	24,68
Navarra	9 417	329	28,62
Cantabria	5 000	200	25,00
Madrid	2 661	96	27,72
Total	2 305 549	74 584	29,73

La producción de patata se extiende durante todo el año, por lo que la caracterización agronómica de este tubérculo se realiza en función de la época de recolección (MAGRAMA, 2016). De este modo se distinguen:

- Patata extratemprana y temprana (del 15 de enero al 15 de junio).
- Patata de media estación (del 16 de junio al 30 de septiembre).
- Patata tardía (del 1 de octubre al 14 de enero).

A nivel económico, se observan grandes diferencias entre los distintos tipos, siendo las patatas temprana y de media estación las mejor remuneradas (Figura 7). Además, hay una gran variabilidad de precios dependiendo del año de cosecha, que varían en función de las condiciones climáticas o de la oferta/demanda del mercado.




Figura 7. Histórico de precios medios nacionales de patatas (€/100 kg) a lo largo de las diferentes semanas del año. (Elaboración propia. Fuente: MAGRAMA, 2018)

Además, según la organización agraria COAG la patata es uno de los productos que mayores incrementos percibe en destino, es decir, mayores diferencias se producen entre el precio que recibe el agricultor y el de venta al público, llegando a producirse diferencias de hasta un 700%.

2.2. Parámetros de calidad de la patata

La composición química y propiedades físicas de los tubérculos condicionan su uso, como patata fresca o como alimento procesado de alto valor añadido. Otros aspectos que determinan también la calidad y uso potencial son los defectos externos o internos, como enverdecimiento, hematomas, pardeamiento enzimático, pardeamiento no enzimático y otros trastornos fisiológicos (Rady y Guyer, 2015). Además, la estimación precisa del tiempo óptimo de cosecha, la variedad y el almacenamiento postcosecha son críticos ya que tienen un impacto directo sobre su calidad (Singh *et al.*, 2016).

La calidad se define como el conjunto de propiedades inherentes a un objeto que le confieren capacidad para satisfacer necesidades o expectativas declaradas e implícitas (ISO 9000:2015 Sistemas de Gestión de Calidad). El tamaño, la textura y el color de la patata son los principales atributos evaluados por el consumidor para determinar la aceptabilidad de las mismas (Kaur *et al.*, 2007).

2.2.1. Propiedades reológicas: Textura

La textura es uno de los cuatro principales factores de calidad en los alimentos (Bourne, 2002; Chen y Opara, 2013), junto con la apariencia, el sabor y el valor nutricional. Los atributos de textura se usan para monitorear y controlar la calidad de las patatas a lo largo de toda su cadena de valor. De este modo se puede evaluar el efecto de la manipulación postcosecha y

del procesamiento en la vida útil del producto, además de la preferencia y aceptabilidad del consumidor. Además, la recolección, el manejo y el almacenamiento pueden producir daños o alteraciones en los tubérculos, de ahí la importancia del estudio de las propiedades mecánicas para mejorar la tecnología de procesos (Soliman y Wersh, 2017).

Según Kaur *et al.* (2007) la textura es la resistencia que ejerce el tubérculo a una fuerza aplicada y ésta varía en función de la estructura celular de la patata. Cuando se aplica un esfuerzo, las células pueden separarse mediante la rotura de la laminilla media o bien pueden estallar, dependiendo de la resistencia de dicha laminilla. Generalmente, las patatas crudas sufren rotura celular (Aguilera y Stanley, 1990). Además de la microestructura, la textura va a depender de la interacción de varios factores como la estructura y composición de la pared celular, el contenido de almidón y la forma y tamaño de los gránulos de almidón (Singh *et al.*, 2016; Semeijn y Buwalda, 2018). El almacenamiento postcosecha también afecta a la calidad textural de este tipo de tubérculos. Mientras que el almacenamiento en refrigeración evita la pérdida de peso, el deterioro y la brotación, la calidad de las patatas se va modificando como resultado de la actividad fisiológica en la que el almidón se va transformando en azúcares reductores. Con el tiempo los azúcares reductores se van acumulando y el almidón se va agotando (Bentini *et al.*, 2009).

La firmeza es un atributo textural importante en este tipo de alimentos ya que se utiliza para evaluar la calidad durante el almacenamiento, la comercialización en fresco o procesado. La dureza y la firmeza de las patatas crudas disminuyen progresivamente con un aumento de temperatura de almacenamiento postcosecha (Kaur *et al.*, 2007).

Las propiedades físicas de los tubérculos pueden evaluarse subjetivamente mediante análisis sensoriales descriptivos u objetivamente mediante técnicas instrumentales. El elevado tiempo y coste asociado al análisis sensorial ha motivado el desarrollo de pruebas instrumentales que se correlacionan con el análisis sensorial de la textura de los alimentos (Chen y Opara, 2013). Los ensayos mecánicos incluyen las pruebas habituales de penetración, punción, compresión y corte, así como los ensayos de fluencia e impacto. La firmeza puede determinarse a través de distintas magnitudes, como la resistencia a la rotura, el módulo de elasticidad o la indeformabilidad, aunque el método normalizado es a través de la medida de resistencia mediante el ensayo de penetración (Barreiro y Altisent, 1996). En los últimos años, la aplicación de tecnologías novedosas y emergentes no destructivas, como la espectroscopía en el infrarrojo cercano (NIRS) y la técnica de imágenes hiperespectrales, cada vez están siendo

más utilizadas para medir los atributos de textura tanto en alimentos frescos como en procesados.

2.2.2. Propiedades ópticas: Color

El color es un indicador de calidad ya que informa del deterioro de los alimentos, alerta sobre el estado higiénico-sanitario y el valor nutricional del producto. Además, el color y la apariencia son responsables del primer contacto del alimento con el consumidor pudiendo condicionar sus preferencias e influir en su elección (Kays, 1999).

Ciertas variedades de patata son capaces de producir antocianinas y otros flavonoides, tanto en la piel como en carne. Las patatas de color rojo y púrpura en comparación con las variedades blancas o amarillas, contienen mayor cantidad de compuestos fenólicos antioxidantes (Valiñas *et al.*, 2017). Estos pigmentos, junto con otros fitoquímicos, son beneficiosos para la salud (Šulc *et al.*, 2017). Además, este tipo de coloración las hace más atractivas, siendo cada vez más demandadas por los consumidores (Tierno *et al.*, 2016).

La colorimetría es una técnica de análisis que permite determinar el color de los alimentos a partir de sus propiedades ópticas, medidas en el rango del espectro visible entre 400 y 700 nm. Su determinación se puede realizar mediante valoración visual o instrumental, los cuales ordenan por coordenadas tridimensionales las características que describen el color. Entre los sistemas cartesianos más usados se encuentra el espacio de color CIE L^*a^*b (Figura 8), que describe las coordenadas L^* (luminosidad), a^* (componente rojo verde), b^* (componente amarillo azul) y atributos cromáticos (croma), y h^* (ángulo de tono). El eje L^* mide la luminosidad de una muestra, donde los valores bajos indican colores oscuros y valores altos colores más claros. Para cada valor de L^* la cromaticidad se define por sus coordenadas en los ejes a^* y b^* . El eje a^* indica colores rojos para valores positivos, y verdes para negativos. El eje b^* indica colores amarillos para valores positivos y azules para valores negativos (Arana, 2012).




Figura 8. Espacio CIELab (Konika Minolta, 2014)

Actualmente, debido a los avances en la óptica e informática es posible aplicar la colorimetría triestímulo en imágenes digitales. De este modo, se obtiene información colorimétrica de cada pixel. Además, la distribución de los pixeles que componen la muestra determinan otros parámetros relacionados con la apariencia, algo que no resulta posible con la colorimetría convencional (Heredia et al., 2016).

2.3. Tecnología NIRS

2.3.1. Bases teóricas

El infrarrojo (IR) corresponde con la región del espectro electromagnético que comprende longitudes de onda de 780 a 10^6 nm. A su vez esta región se divide en 3 zonas, representadas en la Figura 9: Infrarrojo cercano de 780 a 2500 nm (NIR), Infrarrojo medio de 2500 a $5 \cdot 10^4$ nm (MIR) e Infrarrojo lejano de $5 \cdot 10^4$ a 10^6 nm (FIR) (López-Maestresalas, 2016).

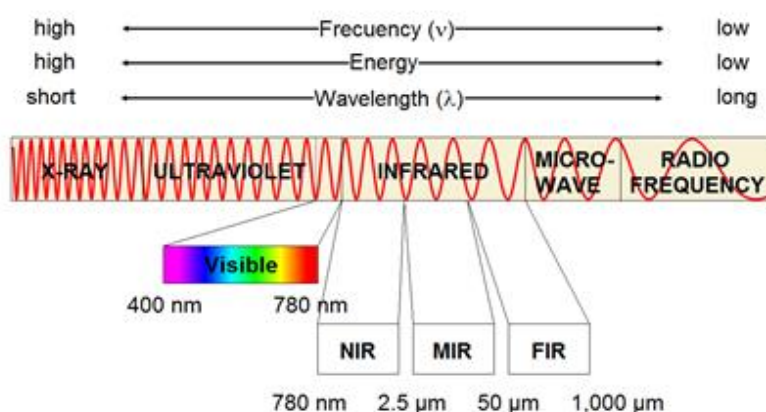


Figura 9. Espectro electromagnético (López-Maestresalas, 2016)

La espectroscopia NIR estudia la interacción de la radiación electromagnética del infrarrojo cercano con la materia. La radiación penetra en la muestra e interactúa con los enlaces de las moléculas, especialmente con las de la forma -CH, -NH, -OH y -CO, que absorben fotones de esa región de acuerdo con sus frecuencias de vibración específicas. Los principales modos vibracionales de las moléculas son el estiramiento (stretching) y la flexión (bending). Las vibraciones de estiramiento producen un cambio continuo de la distancia entre los átomos sin abandonar el eje del enlace, pudiendo ser simétrico o asimétrico, mientras que las de flexión se caracterizan por un cambio en el ángulo de dos enlaces. Una molécula absorbe IR solamente cuando la frecuencia de la radiación coincide con la de los armónicos y las combinaciones de modos vibratorios fundamentales (Pasquini, 2018), que causan un cambio en el momento dipolar de la molécula (Miller, 2001). Cuando esto ocurre, la molécula pasa del estado de vibración fundamental a un estado excitado, aumentando la amplitud del movimiento vibratorio de los átomos del enlace. En especies moleculares homonucleares

como H_2 , O_2 y N_2 , no hay diferencias entre los estados vibracionales, por lo que no absorben radiación en el infrarrojo. Por el contrario, los enlaces que vibran con gran energía y amplitud son los enlaces que contienen átomos de hidrógeno, dando lugar a bandas de gran intensidad (Ozaki *et al.*, 2018).

En el espectro obtenido se representa gráficamente la intensidad de la radiación transmitida o reflejada por la muestra en las diferentes longitudes de onda. De este modo se generan una serie de bandas de absorción a determinadas frecuencias que se corresponden con aquellas frecuencias de transición vibracional que dan las vibraciones características de la molécula. La intensidad de dichas bandas sigue la Ley de Lambert-Beer, que propone que la absorbancia a cualquier longitud de onda es proporcional a la concentración de moléculas absorbentes presentes en el camino de la radiación. De este modo, se pueden realizar determinaciones cuantitativas de una muestra a partir de la identificación cualitativa de las bandas. Sin embargo, los datos NIR tienen una baja selectividad debido a la superposición de bandas de absorción y a la gran cantidad de datos e información redundante (colinealidad) que se obtienen. Por ello, es necesario el uso de métodos multivariantes para extraer información de los espectros NIR (López-Maestresalas, 2016).

2.3.2. Instrumentación

Existen cuatro modos para llevar a cabo las mediciones con espectroscopía NIR: reflectancia, transmitancia, transflectancia e interactancia (Figura 10). La elección del modo de obtención de los datos dependerá del tipo de muestra y componentes que se deseen analizar.

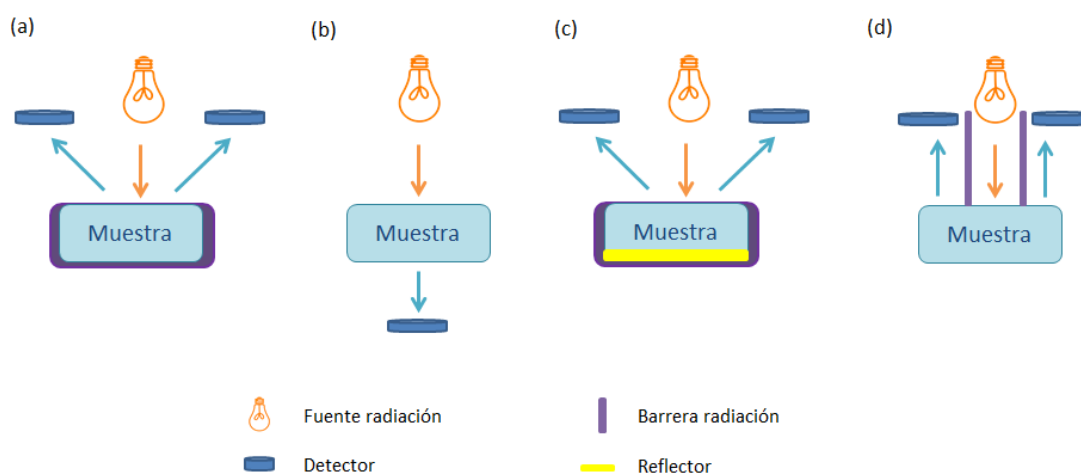


Figura 10. Modos de medición NIRS: (a) reflectancia, (b) transmitancia, (c) transflectancia e (e) interactancia (Elaboración propia)

- **Modo de reflectancia.** La radiación es reflejada por la superficie de la muestra. El detector se sitúa en el mismo lado que la fuente de luz para capturar la luz reflejada.

Mide tanto la reflectancia especular, que no aporta información de la composición interna, como la reflectancia difusa, en la que la luz reflejada ha interactuado con las partículas internas de la muestra aportando información. Generalmente se usa para muestras sólidas o granulares.

- **Modo de transmitancia.** Miden la cantidad de luz transmitida a través de la muestra. El detector está ubicado en el lado opuesto de la iluminación y normalmente se utiliza para el análisis de muestras de líquidos y ciertas muestras sólidas como granos, carne, productos lácteos, etc.
- **Modo de transflectancia.** Es una combinación de reflectancia y transmitancia, en el que la fuente de luz y el detector se colocan paralelos entre sí en el mismo lado del producto.
- **Modo de interactancia.** El detector se separa de la fuente de luz, pero ambos están en contacto directo con la superficie de la muestra, de este modo se evita la medición de la reflectancia especular. Este tipo de medición es más adecuado para muestras grandes, como frutas enteras.

Un equipo NIRS está formado principalmente por 5 componentes: una fuente de radiación, una red de difracción, un portamuestras, un detector fotoeléctrico para medir la intensidad de la luz detectada y convertirla en señales eléctricas, y finalmente un sistema para procesar los datos espectrales (López-Maestresalas, 2016; Bergera *et al.*, 2006).

- **Fuente de radiación.** Existen fuentes continuas y lineales. Las fuentes continuas más utilizadas son las lámparas halógenas de tungsteno, que emiten radiación de alta intensidad de forma continua. Las fuentes lineales se utilizan generalmente cuando no se requiere de un espectro completo, se incluyen los láseres, diodos láser y diodos emisores de luz (LEDs).
- **Red de difracción.** Son unos dispositivos de selección de longitudes de onda que pueden ser móviles en el caso del sistema de filtros y monocromador, o estacionarios para los filtros optoacústicos ajustables (AOFT) y matriz de diodos.
- **Portamuestras.** Es el lugar en el que se coloca la muestra, donde se produce una interacción entre el NIR y el objeto de estudio. Existen gran variedad para los diferentes tipos de análisis (reflectancia, transmitancia, transflectancia e interactancia).
- **Detector.** Es el sensor que mide la intensidad de la radiación NIR y la transforma en señales eléctricas. Según su funcionamiento se distinguen los detectores térmicos y

detectores sensibles a los fotones o fotodiodos. Los detectores térmicos incluyen aquellos dispositivos basados en sulfato de triglicina deuterada (DTGS) junto con termopares, bolómetros y termistores, entre otros. Los detectores sensibles a fotones más usados son los fotodiodos de silicio, arseniuro de galio e indio (InGaAs) y seleniuro de plomo (PbSe).

- **Sistema de adquisición y procesamiento de datos.** Normalmente un microprocesador u ordenador capaz de procesar y analizar datos espectrales utilizando un software específico.

Además, a la hora de seleccionar un dispositivo de medición adecuado es importante tener en cuenta el tipo de muestra y el grado de penetración que existe en las diferentes longitudes de onda. Lammertyn *et al.* (2000) observaron que dentro de la región NIR, entre los 700 y 900 nm la radiación podía penetrar unos 4 mm en el interior de manzanas, mientras que a 900 – 1900 nm solamente 2-3 mm. Esto puede deberse a que las ondas que presentan menor longitud de onda son más energéticas y son capaces de penetrar con mayor facilidad en el alimento.

Según López-Maestresalas (2016) la espectroscopia NIR es una herramienta analítica que presenta una serie de ventajas:

- Técnica no destructiva y no invasiva
- No requiere apenas preparación de la muestra
- Análisis rápido
- Respetuosa con el medio ambiente ya que no genera residuos
- Versátil: puede ser utilizada para diferentes productos
- Permite un análisis rentable
- Un único espectro NIR contiene información tanto física como química de una muestra

Sin embargo, este método presenta algunos inconvenientes que pueden afectar a su implementación en la industria agroalimentaria, como son:

- Dependencia de métodos de referencia basados en análisis físico-químicos
- Precio relativamente alto del equipo
- Dificultad de transferir modelos de un instrumento a otro
- Limitación de uso, ya que los resultados obtenidos sólo son aplicables a muestras con características similares a las que se usaron para desarrollar el modelo
- Necesidad de personal cualificado para llevar a cabo los análisis multivariantes

2.3.3. Quimiometría

Para realizar una evaluación de la calidad, la tecnología NIRS se basa en establecer una relación entre los datos espectrales del producto y sus características físico-químicas, mediante la creación de modelos de calibración. Sin embargo, los espectros NIR contienen grandes cantidades de datos, con mucho ruido e información redundante. Además, según Nicolai *et al.* (2007) los espectros de frutas y verduras son especialmente difíciles de interpretar por varios motivos. El agua es el componente químico mayoritario en este tipo de alimentos y sus bandas de absorción enmascaran y dominan el espectro. Además, la rica composición química del producto da como resultado un conjunto de sobretonos y bandas de combinación que aportan mayor complejidad al espectro. Y por último, el espectro puede complicarse aún más por los efectos de dispersión dependientes de la longitud de onda, la heterogeneidad de los tejidos, el ruido instrumental y los efectos ambientales, entre otros. Por tanto, para poder asignar correctamente las bandas de absorción a grupos funcionales específicos se requiere de técnicas estadísticas multivariantes, también llamadas quimiométricas, donde los datos sufren un tratamiento previo para eliminar la información irrelevante que no puede ser manejada adecuadamente por técnicas de regresión. De este modo, la quimiometría analiza los datos teniendo en cuenta varias variables de forma simultánea y extrae la información útil de los espectros, mejorando significativamente las aplicaciones del NIRS. La quimiometría abarca una amplia gama de métodos que incluyen el pretratamiento de datos espectrales, la construcción de modelos de calibración para el análisis cualitativo y cuantitativo, y la transferencia de modelos (Qu *et al.*, 2015).

2.3.3.1. Análisis cuantitativo

El análisis cuantitativo consiste en estimar la concentración de un compuesto en la muestra a partir de un modelo matemático. Este modelo relaciona los valores de reflectancia NIR y la concentración de dicho compuesto, que ha sido determinada mediante un método de referencia. A continuación se describen los pasos que se deben seguir para desarrollar un modelo robusto y fiable:

Modelo de calibración

Primero se establece una ecuación de calibración para poder predecir el parámetro físico-químico que se desea establecer en otras muestras de características similares a las utilizadas para realizar la calibración. Para su elaboración se distinguen los siguientes pasos (Peguero, 2010):

- **Selección de muestras.** Deberán ser representativas del producto, cubriendo la variabilidad existente para dicho producto. Además, cuanto mayor sea el número de muestras, mayor capacidad de predicción presentará la ecuación.
- **Métodos de referencia.** Se realizan análisis físico-química sobre las muestras para conocer con exactitud el parámetro que se desea estudiar.
- **Registro de la información espectral.** Las medidas más representativas del muestreo en patatas enteras son las mediciones NIR tomadas en el punto central del eje longitudinal del tubérculo (López-Maestresalas, 2016).
- **Selección de las variables espectrales.** Identificar las bandas de absorción del espectro NIR que sean de interés según los parámetros que se desean analizar.
- **Pretratamiento de los datos espectrales.** La complejidad de los espectros hace necesario la aplicación de pretratamientos, mediante las siguientes técnicas (Nicolai *et al.*, 2007):
 - Promedio de espectros. Se lleva a cabo generalmente durante la adquisición del espectro para reducir el ruido térmico de los detectores.
 - Centrado (*Mean Center*). Es un pretratamiento recomendado para todas las aplicaciones técnicas. Se basa en restar a cada variable su promedio para centrar los datos.
 - Suavizado (*Smoothing*). Existen filtros para eliminar el ruido aleatorio de los espectros NIR, incluyendo el algoritmo Savitzky-Golay o la Transformada de Fourier (Peguero, 2010).
 - Derivación. Permite eliminar los cambios en la línea de base y los picos superpuestos. Los más populares son las de segundo orden, ya que pueden corregir tanto los efectos aditivos (desplazamiento de la línea base) como los multiplicativos (inclinación). Los métodos más usados son el de Norris y el de Savitzky-Golay.
 - Normalización. La técnica más habitual es el MSC (Corrección de la dispersión multiplicativa) que se realiza para compensar los efectos aditivos y multiplicativos de los datos espectrales. Este método intenta eliminar los efectos de la dispersión al linealizar cada espectro con el espectro promedio del grupo de calibración.
 - Estandarización. La más utilizada es el SNV (Variable normalizada estándar) que corrige el efecto de la dispersión (*scattering*) mediante el centrado (resta la media) y escalado (divide el espectro de cada longitud de onda entre la desviación estándar de todo el espectro).

- Deducción de tendencia (*Detrending*). Suele llevarse a cabo junto con el SNV para corregir las variaciones de la línea base, aplicando un polinomio de grado bajo en todos los puntos del espectro y posteriormente restándole la curva resultante al espectro.
- **Desarrollo del modelo.** A continuación se elabora la ecuación de calibración, que relaciona los datos espectrales a los que se les ha aplicado un pretratamiento previo, con los resultados obtenidos mediante los métodos de referencia. Para ello, se emplean técnicas de regresión lineal, siendo las más habituales en el análisis cuantitativo la regresión lineal múltiple (MLR), la regresión de componentes principales (PCR) y la regresión de mínimos cuadrados parciales (PLS) (Qu *et al.*, 2015).
- **Eliminación de valores atípicos (*Outliers*).** Durante el proceso de elaboración del modelo de calibración pueden detectarse una serie de valores atípicos (*Outliers*). Estos son valores o datos extremos que no encajan con el resto de muestras que conforman el grupo de calibración. Pueden influir negativamente en la capacidad predictiva del modelo, por lo que su detección, interpretación y posible eliminación adquiere especial relevancia dentro del análisis multivariante de los datos espectrales.

Validación del modelo

La validación del modelo se realiza con el fin de evaluar la exactitud del modelo de calibración. Para ello, se pueden emplear los siguientes procedimientos:

- **Validación cruzada.** Sucesivamente se van eliminando datos del grupo de calibración y se utilizan para validar la ecuación que se ha generado con el resto de los datos que no han sido eliminados. Con cada validación se obtiene un residuo de predicción. El proceso se repite hasta que todas las muestras hayan sido utilizadas una vez en el proceso de validación y al final se estima la variación de todos los residuos de predicción. Una variante de esta técnica es la validación cruzada múltiple, en la que extrae un conjunto definido de datos, en vez de extraer datos individuales para realizar la validación (Nicolai *et al.*, 2007).
- **Validación externa.** En este caso, el conjunto de muestras empleadas para realizar la validación es independiente de las de la calibración. La composición de estas muestras es conocida y además, estas muestras son representativas tanto del conjunto de calibración como de las que se vayan a analizar en un futuro.

2.3.3.2. Análisis cualitativo

El análisis cualitativo permite identificar y clasificar muestras mediante la comparación de los espectros NIR con los de un grupo de muestras con propiedades conocidas. Como en el caso anterior, primero se elabora un modelo de calibración que posteriormente debe ser validado mediante validación cruzada y validación externa. En el análisis cualitativo existen dos métodos para desarrollar el modelo de calibración:

- **Método no supervisado.** La información previa es escasa, por lo que es útil en las primeras etapas de la investigación. El objetivo es identificar la tendencia de agrupamiento de las muestras únicamente con los datos espectrales. Los más utilizados son el análisis de componentes principales (PCA), Cluster jerárquicos y Cluster de partición (no jerárquicos).
- **Método supervisado.** Existe información previa sobre los grupos existentes en el conjunto de muestras. Este método genera reglas de clasificación para agrupar las muestras con las que presenten mayor semejanza en términos estadísticos. Los más empleados son: análisis discriminante mediante el método de PLS (PLS-DA), análisis discriminante lineal (LDA) y cuadrático (QDA), entre otros.

2.3.4. Aplicaciones NIRS en la evaluación de la textura en patata

Los recientes avances han demostrado el potencial de la tecnología NIRS dentro de la industria agroalimentaria. Además, teniendo en cuenta que el entorno normativo y los requisitos de calidad cada vez son más estrictos y exigentes, el uso efectivo de este tipo de estrategias de control y monitorización puede ayudar a garantizar la inocuidad, adulteración y calidad de los alimentos, al tiempo que reduce los costes de producción y aumenta la eficiencia energética (Grassi y Alamprese, 2018).

En patatas, la mayoría de las publicaciones se han centrado en la aplicación de esta tecnología como una herramienta para el control de calidad, realizando estimaciones de la composición química, concretamente del contenido de humedad, almidón, materia seca, grasa y contenido en compuestos fenólicos, entre otros (Escuredo *et al.*, 2018). Si bien es cierto que hay autores que han estudiado la relación entre los espectros NIR y la caracterización textural de patatas, la mayoría de las publicaciones se centran en patata procesada en vez de cruda, ya que es la forma más habitual de consumirla. De este modo, Boeriu *et al.* (1998) estudiaron la capacidad de la espectroscopia NIR para estimar los atributos sensoriales de textura de las patatas cocidas al vapor. Se evaluaron sensorialmente patatas tras 1, 3 y 6 meses de almacenamiento.

Los espectros NIR se registraron en las mismas muestras de patata en el rango espectral de 1100 a 2500 nm y se les aplicó un modelo cuantitativo de regresión PLS. Los autores obtuvieron un coeficiente de correlación (R) de 0,82 con un error estándar de predicción (SEP) de 8,64. Los resultados del estudio mostraron que los atributos texturales como la harinosidad y firmeza en patatas cocidas, pueden ser medidas con precisión mediante NIRS. En otro estudio llevado a cabo por Thybo *et al.* (2000) se prepararon muestras de patata tanto cruda como cocida y se obtuvieron sus espectros NIR en el rango de longitud de onda de 400 a 2498 nm. De igual modo, los resultados obtenidos por regresión PLS presentaron una buena correlación entre los datos espectrales y la harinosidad, con una R de 0,83 para la patata cocida y 0,73 para la cruda.

Otra posible aplicación podría ser la identificación de patatas transgénicas mediante el uso de esta tecnología. La mayoría de regiones del mundo ha limitado su explotación y aplicación, especialmente en Europa, por lo que se hace imprescindible su identificación (Qu *et al.*, 2015). En el estudio llevado a cabo por Xie *et al.* (2007) en tomates, obtuvieron resultados bastante buenos con una R de 0,98, lo que les permitió separar rápidamente los alimentos transgénicos y no transgénicos mediante el uso del NIRS.

Sin embargo, aunque el número total de publicaciones en el campo de la espectroscopía NIR está aumentando constantemente año tras año, la mayoría de los estudios se han llevado a cabo en laboratorio, mientras que las aplicaciones a nivel industrial todavía son escasas (Qu *et al.*, 2015). Las propiedades extremadamente diversas y variables de las materias primas, las transformaciones que ocurren durante el procesamiento y la naturaleza perecedera de los productos pueden ser los motivos que dificultan su implementación dentro de la industria alimentaria (Grassi y Alamprese, 2018).

3. Material y métodos

3.1. Diseño experimental

Como se menciona con anterioridad, el objetivo de este trabajo se basa en estudiar la viabilidad de la tecnología NIRS para evaluar la calidad de la patata cruda y de este modo, determinar si es una herramienta fiable para predecir y clasificar los tubérculos según su textura. Así como estudiar las variaciones de peso y color que ocurren a lo largo del almacenamiento de diferentes variedades de patata.

A continuación se describen de forma detallada los pasos desarrollados durante este estudio (Figura 11):

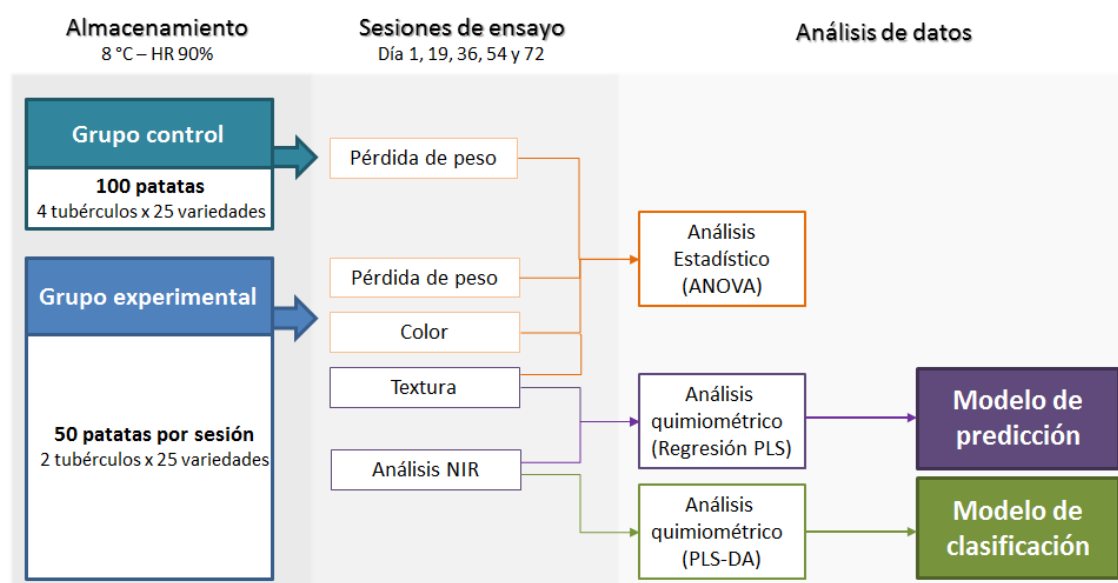


Figura 11. Esquema del diseño experimental

Concretamente se han analizado un total de 350 patatas de 25 variedades diferentes (14 tubérculos por variedad) pertenecientes al Instituto Vasco de Investigación Y Desarrollo Agrario (NEIKER-Tecnalia). Los ensayos se realizaron entre los meses de Diciembre a Marzo de 2018 en intervalos de dos semanas aproximadamente. Los tubérculos se dividieron en dos grupos:

- **Grupo control.** Se seleccionaron 4 patatas por variedad, 100 en total, que se identificaron y mantuvieron refrigeradas durante todo el proceso experimental a 8°C con una humedad relativa de 90%. Este grupo fue sometido a análisis de control de pérdida de peso cada dos semanas aproximadamente, tras lo cual las patatas volvían a la cámara hasta el siguiente día de ensayo.
- **Grupo experimental.** El resto de tubérculos (250 patatas) se mantuvieron refrigerados bajo las mismas condiciones que los del grupo control. En cada sesión se elegían al azar solamente 2 tubérculos por variedad. Tras identificarlos, se evaluaba empíricamente la calidad de los mismos midiendo el peso, el color de la piel y la textura. Además, se adquirían sus espectros NIR. Después de realizar todos los ensayos, las patatas de este grupo (50 cada vez) eran desechadas.

Los datos de pérdida de peso obtenidos del grupo control así como del experimental y los parámetros de color y textura del grupo experimental en cada día de ensayo, se estudiaron estadísticamente mediante el análisis de la varianza (ANOVA). Por otro lado, se establecieron correlaciones matemáticas mediante:

- **Regresión PLS** entre los datos de textura y los espectros NIR del grupo experimental para crear un modelo de predicción de la textura de las patatas.
- **PLS-DA** entre los datos espectrales y los grupos de clasificación con el fin de elaborar un modelo de clasificación de los tubérculos según sus diferencias espectrales.

3.2. Material vegetal

Para este estudio se utilizaron 25 variedades de patatas pertenecientes al Instituto Vasco de Investigación Y Desarrollo Agrario (NEIKER-Tecnalia). Todas estas variedades están incluidas en programas de mejora genética llevados a cabo actualmente en este instituto. En la Tabla 3 se muestran de forma detallada las variedades empleadas.

Tabla 3. Variedades de patata estudiadas donde se indica el color de piel y carne (Am: amarilla, Bl: blanco, Ro: roja, y Vi: violeta), textura (F: firme, H: harinosa) y madurez (Temprana, Semitemprana, Semitardía, Tardía e Indefinida) (Origen: NEIKER Arkaute, Álava)

Variedad	Color piel	Color carne	Textura	Madurez
Nela	Am	Am	F	Temprana
Orchestra	Am	Am	F	
Roja Riñon	Ro	Bl	F	
Ambition	Am	Am	F	
Zorba	Am	Am	H	Semitemprana
Monalisa	Am	Am	F	
Draga	Am	Am	F	
Kennebec	Am	Bl	F	
Miren	Am	Am	F	Semitardía
Agria	Am	Am	H	
Harana	Am	Am	F	
Rodeo	Ro	Bl	F	
Leire	Am	Am	F	Tardía
Mirari	Am	Am	F	
Brodict	Am	Am	F	Indefinida
Entzia	Vi	Vi	F	
Soprano	Am	Am	F	
Europima	Am	Am	–	
Action	Am	Bl	–	
Megara	Am	Am	–	
Liberta	Am	Am	–	
Martina	Am	Am	–	
Sante	Am	Am	F	
Picobello	Am	Am	–	
Sin nombre	Am	Am	–	

3.3. Instrumentación

3.3.1. Balanza

Para registrar el peso de los tubérculos y así poder analizar pérdida de peso producida a lo largo del periodo de almacenamiento, se empleó la balanza de precisión Mettler Toledo SB16001. El peso de las patatas se registró en gramos, con un error de $\pm 0,1$ g. Se calculó el peso medio por variedad y día, así como su desviación estándar. La pérdida de peso se expresó en tanto por ciento.

3.3.2. Espectrofotómetro

La colorimetría de la piel de tubérculos se realizó con el espectrofotómetro Konika Minolta, modelo CM-2500d (Figura 12). Este dispositivo calcula la reflectancia espectral en el rango del espectro visible de 400 a 700 nm, a intervalos de 10 nm y a partir de ellas, calcula las coordenadas de color en el espacio CIELab. Se utilizó la reflexión difusa, observador de 8° ($d/8^\circ$) e iluminante CIE D65. Este equipo dispone de una esfera integradora de 52 mm de diámetro y dos lámparas de xenón pulsadas (Konika-Minolta, 2014).



Figura 12. Espectrofotómetro Konika Minolta, modelo CM-2500d (Konika Minolta, 2014)

Cada día de ensayo el equipo se calibraba según las indicaciones del fabricante. Sobre cada tubérculo se realizaron 4 medidas, concretamente en la zona ecuatorial en posiciones opuestas y perpendiculares dos a dos. Posteriormente se calculó el valor medio de cada parámetro de color y desviación estándar para cada patata. El cálculo de la diferencia de color total (ΔE) se realizó con la siguiente ecuación (ec 1).

$$\Delta E_{72-1} = [(L^*_{72} - L^*_{1})^2 + (a^*_{72} - a^*_{1})^2 + (b^*_{72} - b^*_{1})^2]^{1/2} \quad (\text{ec } 1)$$

3.3.3. Texturómetro

El análisis de la textura de las patatas se realizó mediante ensayos de punción. Para ello se utilizó la máquina universal de ensayos TA-XT2Plus de *Stabla Micro Systems* (Figura 13) con el programa informático *Texture Exponent*.




Figura 13. Texturómetro TA-XT2Plus de *Stabla Micro Systems* durante ensayo de punción.

El equipo consta de un brazo móvil al que se acopla una sonda, en este caso una aguja de punción de acero inoxidable P/2N, y una plataforma sobre la que se coloca la muestra. La sonda penetraba en cada tubérculo a una velocidad de 0,5 mm/s y una profundidad de 20 mm, previamente establecidas.




Figura 14. Curva Fuerza-deformación (N/mm) obtenida del ensayo de punción de los tubérculos.

En la Figura 14 se representa la gráfica obtenida en el ensayo de punción. Una vez aplicada la macro correspondiente, se extraen los siguientes parámetros:

- **Fuerza de rotura de la piel (Fpiel).** Medida en Newtons (N) de la fuerza necesaria para romper la piel del tubérculo.
- **Pendiente Fpiel.** Pendiente de la curva fuerza-deformación (curva de carga) desde el origen hasta la Fpiel, medida en (N/mm).
- **Fuerza máxima de punción (Fmax).** Medida de la fuerza (N) que opone la muestra a ser penetrada.
- **Pendiente Fmax.** Pendiente (N/mm) de la curva fuerza-deformación desde el origen hasta la Fmax.

En este estudio se realizaron 4 punciones por patata, y de igual modo que en la medida del color y análisis NIR, en la zona ecuatorial en posiciones opuestas y perpendiculares dos a dos. Posteriormente, se calculó la media de cada parámetro textural y desviación estándar para cada tubérculo.

3.3.4. Equipo NIRS

Los espectros de reflectancia de las diferentes patatas se obtuvieron mediante un espectrofotómetro Brimrose Luminar 5030 (Figura 15), que utiliza la tecnología AOTF (Filtro optoacústico ajustable). El funcionamiento del equipo se basa en la emisión de un haz de luz que irradia la muestra. El haz incide sobre la muestra, parte de la luz es reflejada y recogida por un detector InGaAs. Este detector envía señales que son leídas y tratadas por el programa informático *The Unscrambler X* (CAMO, Stat-Ease, Inc). En este estudio, posteriormente se migraron los datos espectrales a un archivo Excel para ser procesados en el entorno de MATLAB.



Figura 15. Espectrofotómetro Brimrose Luminar 5030

Antes de realizar las mediciones, cada día de ensayo el equipo se calibraba utilizando uno de los tubérculos, asumiendo que la medición era correcta y que el equipo estaba correctamente calibrado cuando la ganancia del amplificador interno del equipo tuviese valores entre 33.000 y 66.000 (Cuesta *et al.*, 1991).

Las mediciones se realizaron a intervalos de 2 nm, en el rango espectral entre 1100 - 2300 nm, con una velocidad de escaneo de 16000 longitudes de onda por segundo. En cada medición, el espectrofotómetro toma 50 espectros para proporcionar un espectro medio compuesto por los valores de reflectancia para cada longitud de onda del rango espectral medido. De este modo, se toman 601 datos de reflectancia por espectro.

La toma de los espectros se llevó a cabo en cuatro puntos de la zona ecuatorial del tubérculo (opuestos y perpendiculares dos a dos), utilizándose posteriormente el espectro medio.

3.4. Análisis quimiométrico: Desarrollo del modelo

3.4.1. Regresión PLS

Para poder predecir la textura de la patata mediante técnicas no destructivas, se ha realizado una regresión PLS para correlacionar la información espectral NIR de las muestras del grupo experimental con la información física obtenida mediante los ensayos de punción.

En este estudio la matriz X está definida por los valores de reflectancia en cada longitud de onda del espectro NIR y las diferentes matrices Y corresponden tanto a los valores de fuerza máxima y fuerza de rotura de la piel como a los valores de ambas pendientes de las curvas de carga obtenidas con el texturómetro para las diferentes variedades de patata. De este modo, se realizaron 4 análisis de regresión PLS, uno para cada matriz Y.

Para ello, las patatas del grupo experimental de los diferentes días de ensayo y sus datos físicos y espectrales asociados (n=250), se dividieron de forma aleatoria entre:

- ✧ **Grupo de calibración.** N=175 (70%)
- ✧ **Grupo de validación.** N=75 (30%)

Para la elaboración del modelo se emplearon las muestras pertenecientes al grupo de calibración, mientras que las del grupo de validación se utilizaron para evaluar externamente su capacidad predictiva. Antes de desarrollar el modelo, se aplicaron diferentes pretratamientos. Primero se llevó a cabo una reducción de la dispersión de los espectros mediante el método de normalización MSC, así como combinándolo con la primera derivada. De igual modo se aplicó una estandarización SNV en solitario, para después combinarlo con la primera derivada y posteriormente con un *Detrend*. La primera derivada se aplicó por el método de *Savitzky-Golay* para una ventana de 7 puntos y un polinomio de segundo grado. Por último, se realizó un centrado de los datos (*Mean Center*).

Los modelos creados se evaluaron en base a varios parámetros:

- **Coeficientes de determinación (R^2).** Para los parámetros estimados frente a los medidos, tanto en la validación cruzada (R^2_{cv}) como en la validación externa o predicción (R^2_p). El coeficiente de determinación indica la proporción de varianza explicada por X, por lo que cuanto mayor sea, mejor será la bondad del ajuste del modelo. Según Williams (2003) un modelo con un valor de R^2 mayor que 0,91 puede considerarse excelente. Con una R^2 entre 0,90 y 0,82 el modelo puede llegar a emplearse para la mayoría de aplicaciones, mientras que si se encuentra entre 0,81 y

0,65 solo para pruebas de cribado. Finalmente modelos con una R^2 entre 0,65 y 0,50 únicamente pueden aplicarse para discriminar entre concentraciones altas y bajas del parámetro estudiado.

- **Errores de predicción del modelo.** Definidos como el error cuadrático medio en la validación cruzada (RMSECV) y error cuadrático medio en la predicción (RMSEP). Para la construcción del modelo se empleó el número de Variables Latentes (LVs) que minimizaban el RMSECV.
- **Ratio de desviación de la predicción (RPD).** Se define como el ratio entre la desviación estándar de la variable respuesta, es decir, fuerza máxima, fuerza de rotura de la piel y pendientes de ambas curvas de carga, y el RMSEP. Un RPD entre 1,5 y 2 significa que el modelo puede discriminar cuando los valores de la variable respuesta son elevados; un valor entre 2 y 2,5 indica que son posibles las predicciones cuantitativas groseras; entre 2,5 y 3 corresponde con un buen modelo y finalmente si es superior a 3 la precisión del modelo es excelente (Nicolai et al., 2007).

La evaluación de los datos anómalos u *outliers* se realizó teniendo en cuenta los residuales-X y el *Leverage* (Nicolai et al., 2007). En el desarrollo de los modelos de regresión PLS, aquellos datos con un residual o un *Leverage* anómalo fueron eliminados, procediendo después a la repetición del desarrollo del modelo de calibración.

3.4.2. PLS-DA

Con el análisis discriminante por mínimos cuadrados se ha realizado una clasificación de los tubérculos en diferentes grupos a través de sus espectros NIR, teniendo en cuenta que cada grupo presenta una textura diferente en función de los días de almacenamiento.

El PLS-DA es un método de regresión lineal que se combina con el análisis discriminante. De este modo, se establece relación entre las variables predictivas (X) y la variable dependiente (Y). Las columnas de la matriz X están definidas por los datos de reflectancia obtenidos en cada longitud de onda (601) y las filas por el número de muestras analizadas (n). En este caso la matriz Y es una matriz simulada en código binario con el mismo número de filas que la matriz X y el mismo número de columnas que los grupos de clasificación definidos. De esta forma, cada fila de Y será un vector formado por ceros, excepto para los componentes que pertenecen a las muestras de esa categoría, que serán iguales a 1.

$$\begin{pmatrix} X_{11} & X_{12} & \cdots & X_{1\ 601} \\ X_{21} & X_{22} & \cdots & X_{2\ 601} \\ \vdots & \vdots & & \vdots \\ X_{n1} & X_{n2} & \cdots & X_{n\ 601} \end{pmatrix} \quad \begin{pmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \cdots & 1 \end{pmatrix}$$

Matriz X Matriz Y

En este trabajo se han definido 4 grupos de clasificación en función de la textura, ya que aunque el test de ANOVA realizado a los resultados de fuerza máxima estableciese que existían diferencias significativas entre 3 grupos, se consideró más acertado realizar 4 debido a que los días 19 y 36 contenían características intermedias. Por tanto, la matriz respuesta Y estaba compuesta por 4 columnas:

- ✧ **Grupo 1.** (día 1) con el vector [1 0 0 0]
- ✧ **Grupo 2.** (día 19) con el vector [0 1 0 0]
- ✧ **Grupo 3.** (día 36) con el vector [0 0 1 0]
- ✧ **Grupo 4.** (día 54 y 72) con el vector [0 0 0 1]

Una vez definidas las matrices X e Y, y de igual modo que en el apartado anterior, los datos se dividieron entre el grupo de calibración y de validación. A los datos espectrales también se les aplicó pretratamientos (MSC, MSC+1ª derivada, SNV, SNV+1ª derivada y SNV+DT) para mejorar la calidad de los mismos, antes de realizar el análisis PLS-DA.

Para evaluar la precisión de los modelos PLS-DA obtenidos tras realizar la validación cruzada y validación externa, se tuvo en cuenta el porcentaje de muestras clasificadas correctamente. Este parámetro está relacionado con:

- **Sensibilidad.** (De una clase A)
 - Verdaderos positivos (VP). Proporción de muestras de clase A que son correctamente clasificadas en su clase A.
 - Falsos positivos (FP). Proporción de muestras de clase A que se clasifican como B.
- **Especificidad.** (De una clase A)
 - Verdaderos negativos (VN). Proporción de muestras de clase B que son clasificadas en su clase B.
 - Falsos negativos (FN). Proporción de muestras de clase B que se clasifican como A.

Estos parámetros pueden describir del siguiente modo:

$$Sensibilidad = \frac{VP}{VP+FN} \qquad Especificidad = \frac{VN}{FP+VN}$$

Ambos parámetros presentan valores entre 0 y 1, siendo este último el mejor resultado, ya que indica una clara diferenciación entre las muestras estudiadas.

El pretratamiento de los datos y los análisis de regresión PLS y PLS-DA se llevaron a cabo con el programa informático *PLS_Toolbox* (Eigenvector Research Inc. Wenatchee, WA) bajo el entorno MATLAB R2018a (The MathWorks, Natick, MA).

3.5. Análisis estadístico

3.5.1. ANOVA

El análisis de la varianza (ANOVA) es una técnica estadística que tiene como objetivo detectar la influencia de una variable cualitativa (factor) sobre una variable cuantitativa (dependiente). De este modo, permite determinar si existen diferencias significativas entre grupos de datos o por el contrario puede suponerse que sus medias poblacionales no difieren.

En este estudio se realizó ANOVA teniendo en cuenta los factores día de ensayo y variedad de patata, sobre la pérdida de peso producida tanto en el grupo control como en el experimental, así como el color de la piel y textura de los tubérculos del grupo experimental, con un nivel de confianza del 95%. En aquellos casos en los que existían diferencias significativas, se realizó un test de comparación de medias (Test de Duncan) para identificar entre que grupos se producen esas diferencias. El programa informático empleado fue SPSS (*Statistical Package for the Social Science*, versión 23 (SPSS Chicago, IL)).

4. Resultados y discusión

4.1. Parámetros de calidad

4.1.1. Peso

Las patatas del grupo experimental presentaron pesos muy diversos debido al propio genotipo de la variedad. La variedad más pesada fue Agria, que alcanzó un peso medio de 248,28 g, mientras que Mirari, la más ligera, apenas superaba los 83 g (Tabla 4). Entre ambas variedades se registraron diferencias de peso mayores de un 66%.

Otro aspecto importante es la variabilidad individual que presenta cada patata dentro de su propia variedad. De este modo, entre tubérculos de una misma variedad se observaron diferencias de peso de aproximadamente un 26,7%, aunque también se registraron casos extremos como el de las variedades Leire o Harana, que llegaron a alcanzar diferencias de hasta 49% y 48,5% respectivamente.

Tabla 4. Peso medio (g) de cada variedad de patata del grupo experimental con su desviación estándar. Las letras indican si existen diferencias significativas ($p < 0,05$) de peso entre cada variedad.

Variedad	Peso Medio (g)	Variedad	Peso Medio (g)
Agria	248,28 ± 124,81 ^a	Liberta	121,51 ± 45,17 ^{fgh}
Zorba	216,29 ± 75,90 ^{ab}	Brodick	120,17 ± 33,66 ^{fgh}
Leire	214,36 ± 46,19 ^{ab}	Orchestra	109,27 ± 24,79 ^{fgh}
Kennebec	208,22 ± 73,81 ^{ab}	Draga	104,25 ± 35,47 ^{gh}
Sin nombre	203,54 ± 59,87 ^{abc}	Ambition	103,65 ± 33,00 ^{gh}
Picobello	182,74 ± 65,95 ^{bcd}	Rodeo	103,54 ± 34,05 ^{gh}
Monalisa	175,98 ± 83,64 ^{bcde}	Sante	102,43 ± 27,43 ^{gh}
Roja Riñon	158,00 ± 63,68 ^{cdef}	Action	98,65 ± 39,47 ^{gh}
Harana	139,90 ± 29,93 ^{defg}	Nela	97,87 ± 30,14 ^{gh}
Europrima	139,23 ± 30,66 ^{defg}	Soprano	97,57 ± 34,40 ^{gh}
Martina	133,13 ± 39,87 ^{efgh}	Entzia	94,39 ± 15,38 ^{gh}
Miren	132,16 ± 17,01 ^{efgh}	Mirari	83,69 ± 27,70 ^h
Megara	129,00 ± 34,00 ^{efgh}		

En líneas generales el peso medio de los tubérculos de patata fue disminuyendo a lo largo del almacenamiento (Figura 16). Cabe destacar que el aumento de peso entre los días 19 y 36 puede ser debido a la propia variabilidad de las muestras seleccionadas al azar para esos días de ensayo. Tras realizar un análisis estadístico se estableció que existían diferencias significativas entre las patatas del día 1 y las almacenadas durante 72 días.




Figura 16. Evolución del peso (g) de las patatas del grupo experimental a lo largo de los diferentes días de almacenamiento. Las letras indican si existen diferencias significativas ($p < 0,05$) entre los distintos días de almacenamiento.

De igual modo, los tubérculos del grupo control estuvieron almacenados durante los 72 días en las mismas condiciones que el resto y únicamente se pesaron en los días de ensayo. La variedad Europrima destaca por su importante pérdida de peso, ya que llegó a reducirse un 11,31% al final del estudio. En el resto de variedades las pérdidas fueron menores, en torno al 2,16%. Hay que tener en cuenta que la mayoría de las patatas cosechadas se almacenan

durante un período de tiempo prolongado. Según Heltoft *et al.* (2016) durante este tiempo se produce una pérdida de peso que se estima que alcance un 10% del peso inicial. Si hay una pérdida de agua superior, la comerciabilidad de los tubérculos se puede ver afectada debido a la apariencia arrugada poco atractiva. Estas pérdidas se deben a fenómenos como la transpiración, respiración, brotación, cambios en la composición química, daños por temperaturas extremas y enfermedades. Por ello, para minimizar la pérdida de calidad y reducir las pérdidas durante el almacenamiento, se debe hacer especial hincapié en la cosecha pero también en los procesos de almacenamiento del tubérculo.

Otro aspecto importante es que este estudio comenzó en Diciembre y en ese momento variedades tempranas como Nela, Orchesta, Roja Riñón o Ambition llevaban más meses recolectadas que variedades tardías como Brodick y Entzia. Este hecho puede condicionar la pérdida de agua del tubérculo y es por ello que para valorar con exactitud este fenómeno, todas las patatas deberían presentar el mismo tiempo postcosecha. Sin embargo, teniendo en cuenta los resultados obtenidos, las variedades que mejor aptitud presentaron fueron las variedades Soprano y Zorba, ya que las reducciones de peso durante los 72 días apenas superaron el 1%. Por el contrario, Europrima parece no ser una variedad óptima para ser conservada durante largos periodos de tiempo ya que tuvo pérdidas mayores al 10% de peso inicial.

4.1.1. Color

El tiempo de almacenamiento, a las condiciones anteriormente descritas, no influyó sobre las coordenadas de color a^* y b^* de la piel de las patatas. Sin embargo, sí se observaron diferencias significativas en el parámetro de luminosidad (L^*).




Figura 17. Evolución de los parámetros de color a^* , b^* y L^* de las patatas a lo largo de los distintos días de almacenamiento. Las letras indican si existen diferencias significativas ($p < 0,05$) entre las muestras para cada parámetro analizado.

Como se puede observar en la gráfica de la Figura 17, los parámetros de color a^* y b^* se mantuvieron prácticamente constantes en todos los días de ensayo, mientras que la luminosidad fue disminuyendo progresivamente. Este descenso en el parámetro L^* indica que la piel de las patatas fue oscureciéndose con el tiempo. El parámetro a^* , que define los colores rojo verde, alcanzó la mayor puntuación en la variedad Roja Riñón, debido a su piel rojiza. Por el contrario, el parámetro b^* (componente amarillo azul) tomó valores entre 17 y 21 en patatas de piel amarilla, mientras que en la variedad morada, Entzia, únicamente alcanzó los 9,55.

Tabla 5. Diferencias de los parámetros de color L^* , a^* y b^* y diferencia de color total (ΔE) entre el inicio y final del almacenamiento.

Variedad	ΔL^*	Δa^*	Δb^*	ΔE
Ambition	-4,45	-0,13	-3,48	15,96
Zorba	-4,92	-0,28	-2,66	15,69
Mirari	-4,91	0,27	-2,29	14,72
Orchestra	-4,78	1,09	-2,20	14,41
Sin nombre	-4,09	1,82	-1,87	11,77
Draga	-4,25	1,02	-1,48	10,63
Europrima	-3,62	-0,41	-2,36	9,42
Soprano	-2,78	0,78	-1,55	5,37
Liberta	-2,11	0,25	-2,31	4,94
Megara	-1,05	0,38	2,67	4,18
Nela	-2,49	0,88	0,15	3,51
Leire	-2,55	0,37	-0,48	3,43
Picobello	-2,49	0,43	-0,46	3,30
Sante	-2,09	-0,16	-1,37	3,13
Monalisa	1,33	0,21	2,08	3,05
Brodict	0,46	1,27	1,74	2,43
Miren	-0,67	1,27	1,53	2,19
Harana	-1,71	-1,13	0,21	2,12
Roja Riñón	-1,35	1,44	-0,53	2,10
Martina	-1,18	0,43	1,12	1,42
Kennebec	-0,90	-0,76	-1,12	1,32
Action	-0,78	0,30	1,27	1,15
Entzia	-0,54	0,14	0,82	0,49
Agria	—	—	—	—
Rodeo	—	—	—	—

De forma más detallada, en la Tabla 5 se muestran los cambios de color total (ΔE) que sufrieron las diferentes variedades de patata entre el primer y último día de estudio. Las mayores variaciones se produjeron en la luminosidad, seguidas del parámetro b^* (componente amarillo azul) y finalmente, el parámetro a^* (componente rojo verde) que apenas sufrió variación. Las mayores diferencias se registraron en tubérculos de la variedad Ambition, Zorba y Mirari que son las que presentan una piel más amarillenta, es decir, mayor valor de b^* . Por el

contrario, en variedades con menor b^* , que tienden al azul como Entzia, fueron menores las variaciones en el color de su piel durante el almacenamiento.

Como se ha comentado con anterioridad, las variedades presentan distintos estados de madurez debido a que presentan épocas de recolección diferentes. Esto puede haber influido también en las variaciones de color producidas en la piel.

4.1.2. Textura

La fuerza máxima registrada por la sonda del texturómetro y la pendiente de la curva fuerza-deformación descrita durante los ensayos de punción de las patatas, tienden a disminuir a lo largo del almacenamiento de los tubérculos (Figura 18). Existen diferencias significativas entre las patatas del primer día y las analizadas tras 72 días de almacenamiento para ambos parámetros.




Figura 18. Representación gráfica de la fuerza máxima (N) y la pendiente de la curva fuerza-deformación registradas durante los diferentes días de almacenamiento

De igual modo la fuerza necesaria para romper la piel y su pendiente tienen a descender conforme aumenta el tiempo de almacenamiento (Figura 19). En este caso la tendencia no es tan clara como en el caso anterior debido a que la obtención de los datos tiene mayor complejidad. Esta tendencia es lógica ya que como se ha visto, con el tiempo la patata pierde humedad. En alimentos como la patata cruda, cuanto mayor agua contengan más turgentes y firmes se encuentran, por lo que durante el ensayo de punción sus células sufren una fractura frágil. Por el contrario, cuando se marchitan, deshidratan o cocinan se convierten en materiales dúctiles (Heltoft *et al.*, 2016).




Figura 19. Representación gráfica de la fuerza máxima (N) y la pendiente de la curva fuerza-deformación registradas durante los diferentes días de almacenamiento

Patatas firmes como Zorba, Brodick, Entzia y Ambition son las que ofrecieron mayor resistencia a la penetración durante los ensayos de punción, alcanzando los 12,40 N de fuerza máxima en la primera variedad. Por el contrario, variedades con menos firmeza como Nela, Liberta, Monalisa y Martina, apenas requirieron 8 N. En cuanto a la fuerza necesaria para romper la piel de los tubérculos, la variedad Ambition, Roja Riñón y Brodick fueron las variedades con la piel más resistente.

4.2. Análisis quimiométrico

La Figura 20 representa los espectros de reflectancia obtenidos del análisis de cada tubérculo en el rango espectral de 1100 a 2300 nm, previos a la aplicación de pretratamientos matemáticos que mejoran la calidad de los datos.




Figura 20. Espectros de reflectancia de las patatas analizadas en el rango de 1100 a 2300 nm.

Los espectros NIR de los alimentos comprenden amplias bandas derivadas de la superposición de absorciones correspondientes a sobretonos principalmente y a combinaciones de modos de vibración que implican enlaces químicos del tipo: C-H, O-H y N-H (Osborne, 2000). Las bandas de combinación pueden corresponder a más de dos vibraciones diferentes. Sin embargo, estas vibraciones deben corresponder al mismo grupo funcional y deben tener la misma simetría. Además, en los espectros de reflectancia NIR las bandas de absorción de las moléculas que componen la muestra se describen como valles en lugar de picos, ya que la absorbancia es igual a $\text{Log}(1/\text{Reflectancia})$. De este modo, en la Figura 20 se observan claramente valles que se encuentran muy próximos a las tres grandes bandas de absorción del agua, a 1153, 1460 y 1940 nm.

En la Figura 21 se muestran los espectros de las patatas analizadas tras la aplicación de los diferentes pretratamientos.

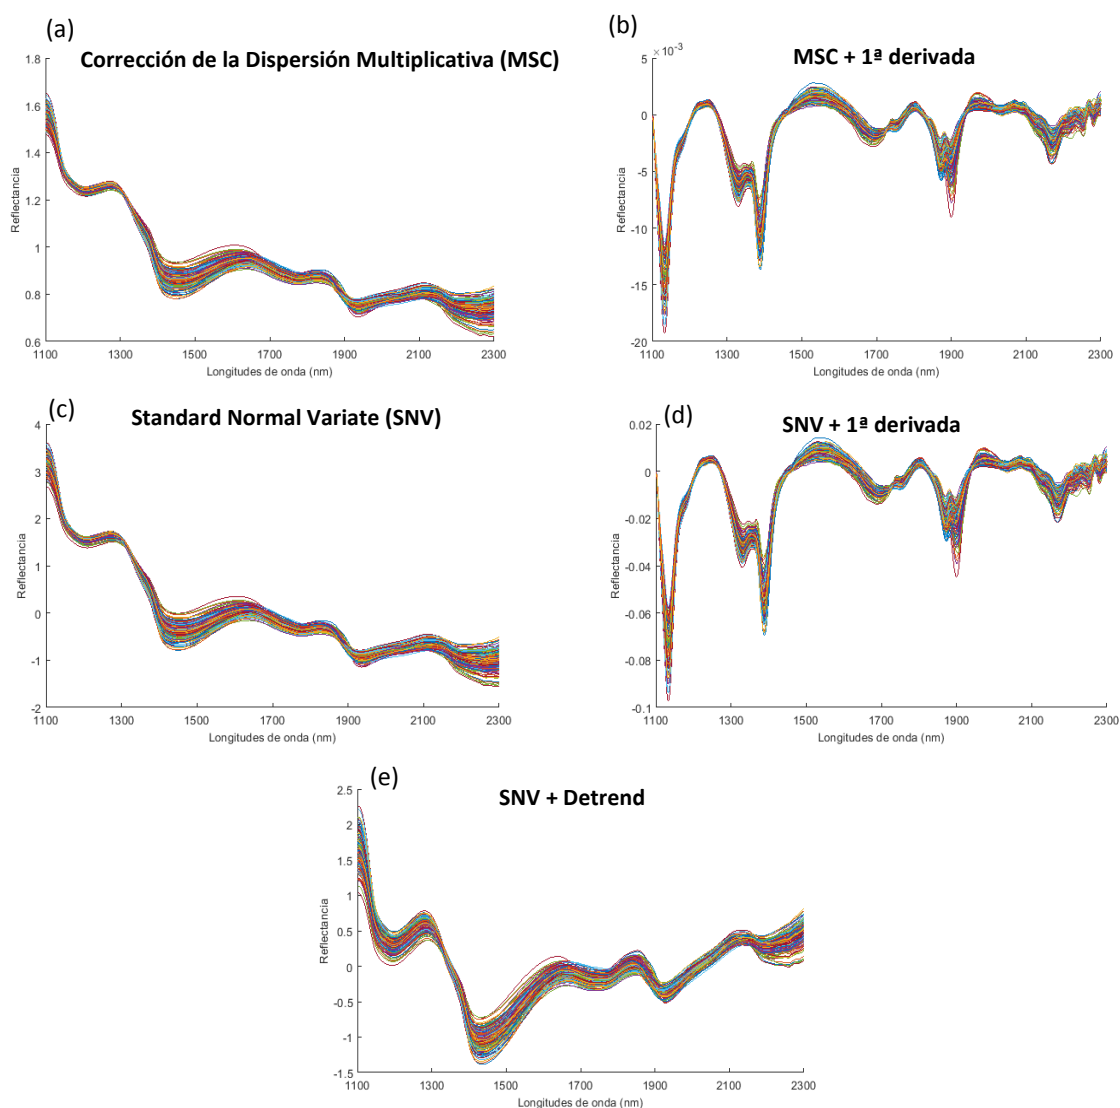


Figura 21. Espectros de reflectancia NIR tras aplicar pretratamientos: (a) MSC, (b) MSC + 1ª derivada, (c) SNV, (d) SNV + 1ª derivada, (e) SNV + Detrend

4.2.1. Modelo de predicción. Regresión PLS

La tabla 6 muestra los resultados obtenidos tras realizar una regresión PLS entre los espectros NIR de los tubérculos analizados y los datos de los diferentes parámetros texturales: fuerza de rotura de la piel, fuerza máxima y las respectivas pendientes de las curvas de carga. En ella se describen los diferentes pretratamientos empleados, además del número de datos (n) y de variables latentes (LVs) utilizadas para la elaboración de los diferentes modelos. También se indican los coeficientes de determinación de la validación cruzada (R^2_{cv}) y de la validación externa o de predicción del modelo (R^2_p), los errores de calibración y predicción (RMSECV y RMSEP) y el ratio de desviación de la predicción (RPD).

Tabla 6. Resultados de la validación cruzada y la predicción de los parámetros fuerza de rotura de la piel (N), fuerza máxima (N) y sus respectivas pendientes de las curvas de carga (N/mm) para los tubérculos de patata.

Parámetro	Pretratamiento	n	LV	R^2_{cv}	RMSECV	R^2_p	RMSEP	RPD
Fuerza rotura piel (N)	MSC	195	10	0,57	0,07	0,51	0,08	1,73
	MSC + 1der	195	8	0,58	0,06	0,49	0,07	1,97
	SNV	195	10	0,59	0,06	0,54	0,07	1,97
	SNV + 1 der	195	8	0,60	0,06	0,47	0,08	1,73
	SNV + DT	195	9	0,53	0,08	0,34	0,08	1,73
Pendiente F. rotura piel (N/mm)	MSC	195	11	0,44	0,44	0,36	0,46	1,60
	MSC + 1der	195	6	0,50	0,36	0,37	0,41	1,79
	SNV	195	10	0,50	0,37	0,43	0,38	1,74
	SNV + 1 der	195	6	0,47	0,39	0,37	0,43	1,71
	SNV + DT	195	10	0,47	0,38	0,41	0,42	1,75
Fuerza máxima (N)	MSC	195	9	0,40	1,19	0,32	1,14	1,41
	MSC + 1der	195	9	0,56	1,09	0,16	1,40	1,14
	SNV	195	9	0,44	1,15	0,27	1,18	1,36
	SNV + 1 der	195	8	0,52	1,06	0,16	1,33	1,21
	SNV + DT	195	9	0,49	1,06	0,30	1,19	1,35
Pendiente F. máx (N/mm)	MSC	195	9	0,33	0,06	0,32	0,05	1,62
	MSC + 1der	195	6	0,41	0,05	0,24	0,05	1,62
	SNV	195	10	0,29	0,06	0,30	0,05	1,62
	SNV + 1 der	195	8	0,52	0,05	0,30	0,05	1,62
	SNV + DT	195	9	0,32	0,06	0,34	0,05	1,62

En líneas generales los resultados de predicción de los modelos desarrollados no son demasiado buenos. Cabe destacar que mientras los coeficientes de determinación en los modelos de predicción de la fuerza máxima y su pendiente apenas presentan capacidad para predecir, ya que apenas superan el valor de 0,30, en la predicción de la fuerza de rotura de la piel se llegan a alcanzar unos R^2_p de 0,51 y 0,54, con unos errores de predicción entre 0,08 y 0,07 y un RPD de 1,73 y 1,97. De acuerdo con Williams (2003), estos modelos podrían ser aplicados para discriminar valores elevados del parámetro estudiado. De igual modo,

atendiendo a su RPD, podrían ser utilizados para diferenciar entre valores altos y bajos del parámetro fuerza de rotura de piel y pendiente de la curva de carga (Nicolai *et al.*, 2007).

A continuación se muestran los dos modelos de predicción de la fuerza de rotura de la piel obtenidos mediante regresión PLS que mejores resultados registraron.




Figura 22. Recta de validación externa del modelo de predicción de la variable fuerza de rotura de piel para los datos pretratados con SNV.

Los resultados del primer modelo se describen en la Figura 22. Para su desarrollo se han empleado 195 datos, 10 variables latentes y aplicado el pretratamiento SNV, con un porcentaje de varianza explicada del 99,87%. El resultado obtenido para la validación con estos pretratamientos ofrece una R^2_p de 0,54 y una RPD de 1,97, por tanto, según lo comentando anteriormente, este modelo podría ser útil para predecir la firmeza del tubérculo cuando se presenten valores altos y bajos en la fuerza de rotura de la piel.

La Figura 23 representa los coeficientes de regresión de las variables utilizadas para el rango de longitud de onda comprendido entre los 1100 y 2300 nm. Este gráfico muestra las variables más influyentes dentro de la ecuación de calibración, que se encuentran próximas a las tres bandas de absorción del agua a 1150, 1400 y 1900 nm. De este modo, el contenido de agua condiciona la firmeza del tubérculo y además, es el compuesto más influyente a la hora de construir este modelo.




Figura 23. Coeficientes de regresión del modelo PLS para la predicción de la fuerza de rotura de la piel de la patata con los pretratamientos SNV mostrando las variables más influyentes en la elaboración del modelo.

Otro modelo de predicción de la variable fuerza de rotura de la piel del tubérculo se representa en la Figura 24. En ella se describe la recta de validación externa del modelo de predicción para los datos pretratados con MSC. Durante el desarrollo del modelo se han utilizado un total de 195 datos y se han seleccionado también 10 variables latentes, explicando un 99,02% de varianza. Se obtuvo un valor de R^2 en la predicción de 0,51 con un PRD de 1,73, lo que indica nuevamente que este modelo puede aplicarse para discriminar entre valores altos y bajos de la fuerza de rotura de la piel del tubérculo.




Figura 24. Recta de validación externa del modelo de predicción de la variable fuerza de rotura de piel para los datos pretratados con MSC.

La Figura 25 representa los coeficientes de regresión obtenidos en el modelo de predicción de la fuerza de rotura de la piel, tras aplicar el pretratamiento MSC. Pueden intuirse las variables que mayor influencia han tenido en la construcción del modelo, y de igual modo que en el modelo anterior, están asociadas a las tres bandas de absorción del agua.




Figura 25. Coeficientes de regresión del modelo PLS para la predicción de la fuerza de rotura de la piel de la patata con los pretratamientos SNV mostrando las variables más influyentes en la elaboración del modelo.

Tras analizar todos los modelos PLS se puede decir que los resultados de predicción no han sido los esperados, ya que ningún modelo desarrollado es lo suficientemente robusto como para predecir de forma precisa y fiable la textura de los tubérculos. Un aspecto importante que puede haber influido en la obtención de estos resultados es que durante la realización de los ensayos hubo problemas externos y todos los equipos tuvieron que ser trasladados a otra ubicación. Aunque posteriormente se realizó una calibración de los mismos, ésta no fue realizada por personal técnico. Por tanto, las mediciones pueden haberse visto afectadas, principalmente las realizadas con el texturómetro, ya que es un equipo pesado y no portátil.

Además, aunque la prueba de punción es un método utilizado por los investigadores para medir la firmeza de la patata, se ha logrado una mejor descripción de la calidad de la textura mediante la prueba de compresión (Arefi *et al.*, 2015). Thybo y Martens (1999) estudiaron las propiedades de textura usando la prueba de compresión en 7 variedades distintas de patata. Las patatas previamente hervidas, fueron analizadas por un panel entrenado que evaluó atributos sensoriales como dureza, firmeza, elasticidad, adhesividad, granulosis, harinosidad y masticabilidad. Paralelamente se realizó una prueba de compresión uniaxial y un análisis del

perfil de textura (TPA) a las muestras de patata. Los resultados mostraron que los parámetros de fuerza-deformación registrados en la prueba de compresión fueron mejores describiendo los atributos sensoriales mecánicos que los parámetros de TPA. Cuando se desarrolló un modelo de regresión de mínimos cuadrados parciales (PLS) utilizando el módulo de deformación, estrés y tensión a la fractura se encontró una correlación relativamente buena (R^2_p 0,76) entre la harinosidad medida y predicha. Por ello, la prueba de compresión puede ser más adecuada en la evaluación de la textura de la patata que otras pruebas destructivas, como el ensayo de punción.

Escuredo *et al.* (2018) llegaron a desarrollar modelos capaces de predecir la textura de la zona apical de los tubérculos crudos con un R^2_p de 0,82 y RPD de 2,2, sin embargo obtuvieron peores resultados a la hora de predecir la textura de la carne, obteniendo un R^2_p de 0,62. En ambos casos se emplearon métodos de regresión de mínimos cuadrados modificados (MPLS) que es una modificación del algoritmo PLS, donde los datos espectrales muestran una mayor correlación con los datos de referencia y por lo tanto, según estos autores, es más estable y precisa que el algoritmo PLS estándar.

4.2.2. Modelo de clasificación. PLS-DA

En la tabla 7 se muestran los pretratamientos que se aplicaron a los espectros NIR, el número de datos que se emplearon para la construcción del modelo PLS-DA, el porcentaje de patatas bien clasificadas en la validación externa y la varianza explicada por cada modelo creado.

Tabla 7. Resultados de los modelos PLS-DA desarrollados.

Pretratamiento	n	LV	% muestras bien clasificadas	Varianza explicada
MSC	167	9	76,38	99,90
MSC + 1der	166	5	61,97	96,01
SNV	179	9	70,83	99,84
SNV + 1 der	166	5	64,79	95,98
SNV + DT	170	9	76,39	99,98

El modelo que mejores resultados obtuvo fue el que recibió un pretratamiento de SNV+DT ya que presentaba un mayor porcentaje de muestras totales bien clasificadas (76,39%) y mayor varianza explicada (99,98%). A continuación se describen con detalle los resultados obtenidos para este modelo.

En la matriz de confusión (Tabla 8) las columnas representan los grupos reales a los que pertenecen las muestras y las filas, el grupo que estima el modelo. De este modo, en la diagonal se encuentran los porcentajes de las muestras que se clasifican correctamente. Las

muestras pertenecientes al grupo 2 son las que mayor porcentaje de acierto presentaron, con un 93,33% de muestras correctamente clasificadas. Cabe destacar que un elevado porcentaje (26,66%) de muestras del grupo 1, se clasificaron erróneamente como grupo 4. Esto supone un error grave, ya que patatas del primer día podrían ser clasificadas como de los últimos días de almacenamiento.

Tabla 8. Matriz de confusión para el modelo PLS-DA con pretratamiento SNV+DT.

		Grupo real (%)			
		1	2	3	4
Grupo estimado (%)	1	66,67	0	7,14	10,71
	2	0	93,33	0	3,58
	3	6,67	0	71,43	10,71
	4	26,66	6,67	21,43	75

En la Figura 26 se representa gráficamente la validación cruzada realizada para obtener el modelo de calibración y la validación externa del modelo. La línea horizontal discontinua indica el umbral por encima del cual una muestra es asignada a un grupo concreto, correspondiendo en este caso a las clasificadas como grupo 2.




Figura 26. Resultados del modelo PLS-DA para los grupos 1, 2, 3 y 4. Estimación para el grupo 2.

Los valores de sensibilidad y especificidad para cada grupo se recogen en la Tabla 9. Del mismo modo, el grupo 2 fue el que mejores resultados obtuvo seguido del grupo 1 y 3, mientras que las patatas del grupo 4 fueron las peor clasificadas.

Tabla 9. Sensibilidad y Especificidad para los diferentes grupos.

	Grupo 1	Grupo 2	Grupo 3	Grupo 4
Sensibilidad	0,867	0,933	0,857	0,679
Especificidad	0,825	0,980	0,879	0,682

Tras analizar los modelos desarrollados, se observa que ninguno de ellos es lo suficientemente robusto y fiable como para clasificar las patatas (PLS-DA) con precisión. Si bien es cierto que los elaborados mediante PLS-DA, ofrecen mejores resultados que los de predicción (PLS), llegando a clasificar correctamente al 76,39% de los tubérculos analizados, no alcanza el nivel de precisión necesario para llegar a implantarlo en la industria agroalimentaria.

5. Conclusiones

Con los resultados obtenidos en este estudio, se pueden extraer las siguientes conclusiones:

- ✧ La pérdida de peso sufrida a lo largo de 72 días se sitúa en torno al 2,16% para todas las variedades, excepto para Europrima que llegó a reducirse un 11,31% al final del estudio, siendo la que peor aptitud presenta para ser almacenada.
- ✧ Todas las patatas estudiadas fueron oscureciéndose con el tiempo. Además, las variedades de piel más amarilla como Ambition, Zorba y Mirari, fueron las que mayores diferencias de color total registraron.
- ✧ Los parámetros texturales como la fuerza de rotura de la piel, la fuerza máxima y sus respectivas pendientes de las curvas de carga, tienden a disminuir con el tiempo. Por tanto, la firmeza de los tubérculos se va reduciendo a lo largo del periodo de almacenamiento.
- ✧ Los modelos de regresión PLS desarrollados para la predicción de la textura en patatas crudas a través de la fuerza de rotura de la piel mediante tecnología NIRS, permitieron realizar estimaciones aproximadas, pudiendo realizar una predicción de acuerdo a valores altos y bajos del parámetro estudiado.
- ✧ Los modelos PLS-DA elaborados para la clasificación de los tubérculos según sus espectros NIR, alcanzaron un nivel de acierto del 61 al 76%, pudiendo realizar una clasificación grosera de los mismos.

- ✧ Los pretratamientos que mejores resultados de predicción del parámetro fuerza de rotura de la piel registraron, fueron el SNV y MSC, alcanzando una R^2P de 0,54 y 0,51 respectivamente. Por el contrario, para la elaboración de un modelo clasificación, con el pretratamiento SNV+DT se alcanzó el mayor nivel de acierto, llegando a clasificar correctamente un 76,39% de los tubérculos analizados.
- ✧ Las variables más influyentes para elaborar el modelo de calibración mediante regresión PLS se encontraron próximas a las tres bandas de absorción del agua. Por tanto, el agua condiciona la firmeza del tubérculo y es el compuesto más influyente a la hora de construir este modelo.

Los resultados obtenidos en este estudio plantean la necesidad de seguir investigando para mejorar las técnicas de predicción de la textura y clasificación de los tubérculos en función de sus espectros NIR. Así de este modo, poder alcanzar estrategias de control y monitorización robustas y fiables que permitan garantizar la calidad de los tubérculos, reduciendo además los costes de producción.

6. Bibliografía

- Aguilera, M.J. y Stanley, D.W. (1990). *Microstructural Principles of Food Processing and Engineering* (second ed.) Elsevier Applied Science, New York, 175–329
- Arana, I. (2012). Chapter 4. Optical Properties of Foods written by Begona Hernandez Salueña and Carlos Saenz Gamasa. In *Physical Properties of Foods: Novel Measurement Techniques and Applications*. Taylor y Francis.
- Arefi, A., Moghaddam, P.A., Mollazade, K., Hassanpour, A., Valero, C. y Gowen, A. (2015). Mealiness Detection in Agricultural Crops: Destructive and Nondestructive Tests: A Review. *Comprehensive Reviews in Food Science and Food Safety*, 14, 657-680
- Barreiro, P., y Ruiz Altisent, M. (1996). Propiedades mecánicas y calidad de frutos. Definiciones y medidas instrumentales. *Fruticultura profesional*, 77, 48-55.
- Bentini, M., Caprara, C., Martelli, R. (2009). Physico-mechanical properties of potato tubers during cold storage *Biosystems Engineering*, 104, 25–32
- Berg, F., Lyndgaard, C.B., Sørensen, K.M. y Engelsen, S.B. (2013). Process Analytical Technology in the food industry. *Trends Food Sci Technol*, 31:27-35.
- Bergera, G., Jarén, C., Arazuri, S., y Arana, I. (2006). Instrumentación para la espectroscopía de infrarrojo cercano. *Horticultura: Revista de industria, distribución y socioeconomía hortícola: frutas, hortalizas, flores, plantas, árboles ornamentales y viveros*. 194, 30-33.
- Birch, P.R.J., Bryan, G. Fenton, B., Gilroy, E.M., Hein, I., Jones, J.T., Prashar, A., Taylor, M.A., Torrance, L. y Toth, I.K. (2012). Crops that feed the world 8: Potato: are the trends of increased global production sustainable?. *Food Security*. 4(4): 477–508
- Boeriu, C., Yuksel, D., Van der Vuurst de Vries, R., Stolle-Smits, T., y Van Dijk, C. (1998). Correlation between near infrared spectra and texture profiling of steam cooked potatoes. *Journal of Near Infrared Spectroscopy*, 6(A), 291-297.
- Bourne, M.C. (2002). Chapter 1- Food Texture and Viscosity. Concept and measurement. *Food Science and Technology*. 2 ed. Academic Press.1-32.
- Bradshaw, J.E. y Ramsay, G. (2009). Chapter 1-Potato Origin and Production in *Advances in Potato Chemistry and Technology*. 1 Ed. Elsevier, 1-26.
- Burton, W. G. (1989). *The potato*. John Wiley and Sons, Inc, New York.
- Chen, L. y Opara, U.L. (2013). Texture measurement approaches in fresh and processed foods — A review, *Food Research International*, Volume 51, 2, 823-835.
- Cuesta, L. M., Gil, A. J. y Remiro, F. (1991). *Electrónica Analógica*: McGraw-Hill/Interamericana S.A.
- Escuredo, O., Seijo-Rodríguez, A., González-Martín, M.I., Rodríguez-Flores, M.S., Seijo, M.C. (2018). Potential of near infrared spectroscopy for predicting the physicochemical

- properties on potato flesh, *Microchemical Journal*, ISSN 0026-265X, <https://doi.org/10.1016/j.microc.2018.06.008>.
- FAO, 2016a. Datos: Cultivos. Consultada el 04/06/2018, en <http://www.fao.org/faostat/es/#data/QC/visualize>
- FAO, 2016b. Datos: Producción: Cultivos. Consultada el 04/06/2018, en <http://www.fao.org/faostat/es/#data/QC>
- FAO, 2013a. Datos: Suministro alimentario-Cultivos Equivalente primario. Consultada el 04/06/18, en <http://www.fao.org/faostat/es/#data/CC>
- FAO, 2013b. Datos: Balances Alimentarios. Consultada el 04/06/2018 en <http://www.fao.org/faostat/es/#data/FBS>
- Grassi, S. y Alamprese, C. (2018). Advances in NIR spectroscopy applied to process analytical technology in food industries, *Current Opinion in Food Science*, Volume 22, 17-21
- Heltoft, P., Wold, A.B. y Molteberg, E.L. (2016). Effect of ventilation strategy on storage quality indicators of processing potatoes with different maturity levels at harvest. *Postharvest Biology and Technology*. 117, 21-29.
- Heredia, F.J., Vicario, J.M., González, M.L., Escudero, M.L., Meléndez, A.J., Gordillo, B., Hernández, J.M., Cejudo, M.J., Stinco, C.M., Rodríguez, F.J., Jara, M.J., Nogales, J., Baca, B., Moreno, F., Rivero, F.J., Mapelli, P., Benítez, A., Alonso, S., Bejines, E. (2016). Investigación en color y calidad de alimentos. III Jornada de Investigación y Postgrado. Libro de actas. Escuela Universitaria Politécnica de Sevilla, 144.
- Jarén, C., López, A. y Arazuri, S. (2016). Chapter 19: Advanced Analytical Techniques for Quality Evaluation of Potato and Its Products in *Advances in Potato Chemistry and Technology*. Elsevier, 563-602.
- Kaur, L., Singh, J., Singh, N. y Ezekiel, R. (2007). Textural and pasting properties of potatoes (*Solanum tuberosum* L.) as affected by storage temperature *Journal of the Science of Food and Agriculture*, 87, 520–526
- Kays, S.J., (1999). Preharvest factors affecting appearance. *Postharvest Biology and Technology* 15, 233–247
- Konika Minolta (2014). Entendiendo el espacio de color CIELab. Consultada el 30/06/2018 en <http://sensing.konicaminolta.com.mx/2014/09/entendiendo-el-espacio-de-color-cie-lab/>
- Lammertyn, J., Peirs, A., De Baerdemaeker, J. y Nicolaï, B. (2000). Light penetration properties of NIR radiation in fruit with respect to non-destructive quality assessment. *Postharvest Biol. Technol.* 18, 2, 121–132
- López-Maestresalas, A. (2016). Near-infrared spectroscopy and hyperspectral imaging for non-destructive quality inspection of potatoes. Universidad Pública de Navarra.

- Lutaladio, N.B. y Castaldi, L. (2009). Potato: The hidden treasure. *Journal of Food Composition and Analysis* 22, 491–493
- MAGRAMA, 2016. Consultada el 06/06/2018, en <http://www.mapama.gob.es/es/estadistica/temas/publicaciones/anuario-de-estadistica/2017/default.aspx>
- MAGRAMA, 2018. Consultada el 06/06/2018, en http://www.mapama.gob.es/app/precios-medios-nacionales/pmn_historico.asp?codigo=22
- Miller, C. E. (2001). Chemical principles of near-infrared technology. In P. Williams y K.H. Norris (Eds.), *Near-infrared Technology in the Agricultural and Food Industries* (Second ed). Minesota, USA: American Association of Cereal Chemists, Inc. 17-34
- Naciones Unidas (2017). Consultada el 06/06/2018, en <http://esa.un.org/unpd/wpp/index.htm>
- Nicolai, B.M., Beullen, K., Bobelyn, E., Peirs, A., Saeys, W., Theron, K.I. y Lammertyn, J. (2007). Nondestructive measurement of fruit and vegetable quality by means of NIR spectroscopy: A review. *Postharvest Biology and Technology* 46, 99–118.
- Osborne, B. (2000). Chapter 1 - Near infrared spectroscopy in food analysis. BRL Australia Ltd, NorthRyde, Australia. Wiley, New York, 1–14.
- Ozaki, Y., Huck, C.W. y Beć, K.B. (2018). Chapter 2 - Near-IR Spectroscopy and Its Applications, In *Molecular and Laser Spectroscopy*, edited by V.P. Gupta, Elsevier, 11-38.
- Pasquini, C. (2018). Near infrared spectroscopy: A mature analytical technique with new perspectives – A review. *Analytica Chimica Acta*, 1026, 8-36.
- Pegueró, A. (2010). La espectroscopia NIR en la determinación de propiedades físicas y composición química de intermedios de producción y productos acabados. Universitat Autònoma de Barcelona.
- Qu, J.H., Liu, D., Cheng, J.H., Sun, D.W., Ma, J., Pu, H. y Zeng, X.A. (2015). Applications of Near-infrared Spectroscopy in Food Safety Evaluation and Control: A Review of Recent Research Advances, *Critical Reviews in Food Science and Nutrition*, 55, 13, 1939-1954.
- Rady, A.M. y Guyer, D.E. (2015). Rapid and/or nondestructive quality evaluation methods for potatoes: A review, *Computers and Electronics in Agriculture*, 117, 31-48.
- Semeijn, C., y Buwalda, P.L. (2018). Chapter 9 - Potato Starch, In *Woodhead Publishing Series in Food Science, Technology and Nutrition*, edited by Malin Sjöö and Lars Nilsson, Woodhead Publishing, *Starch in Food* (Second Edition). 353-372.
- Señán, G. (2010). El consumo en tiempos de crisis: una aproximación sociológica a la distribución del gasto en España. *Aposta. Revista de Ciencias Sociales*, 45, 1-24.
- Shing, J. y Kaur, L. (2009). *Adeances in Potato Chemistry and Technology*. Academic Press, 22.

- Singh, J., Kaur, L., y Rao, M.A. (2016). Chapter 16 - Textural Characteristics of Raw and Cooked Potatoes, In *Advances in Potato Chemistry and Technology* (Second Edition), Academic Press, San Diego, 475-501.
- Soliman, S.N. y Wersh, A.E. (2017). Creep behavior of potato tubers during storage. *Misr J. Ag. Eng.*, 34, 4, 2277 - 2290
- Šulc, M., Kotíková, Z., Paznocht, L., Pivec, V., Hamouz, K. y Lachman, J. (2017). Changes in anthocyanidin levels during the maturation of color-fleshed potato (*Solanum tuberosum* L.) tubers. *Food Chemistry* 237, 981-988.
- Tanios, S., Eyles, A., Tegg, R. y Wilson, C. (2018). Potato Tuber Greening: a Review of Predisposing Factors, Management and Future Challenges. *American Journal of Potato Research* 95, 248–257
- Thybo, A.K., Bechmann, I.E., Martens, M. y Engelsen, S.B. (2000). Prediction of sensory texture of cooked potatoes using uniaxial compression, near-infrared spectroscopy and low-field 1 h NMR spectroscopy. *LebensmWiss u Technol* 33, 2, 103–11.
- Tierno, R., López, A., Riga, P., Arazuri, S., Jarén, C., Benedicto, L. y Ruiz de Galarreta, J.I. (2016). Phytochemicals determination and classification in purple and red fleshed potato tubers by analytical methods and near infrared spectroscopy. *Journal of the Science of Food and Agriculture*. 96, 6, 1888-1899.
- UNE-EN ISO 9001:2015, Sistemas de gestión de la calidad, Asociación Española de Normalización y Certificación [AENOR].
- Valiñas, M.A., Lanteri, M.L., ten Have, A. y Andreu, A.B. (2017). Chlorogenic acid, anthocyanin and flavan-3-ol biosynthesis in flesh and skin of Andean potato tubers (*Solanum tuberosum* subsp. *andigena*). *Food Chemistry* 229, 837-846.
- Williams, P. (2003). Near-infrared technology—Getting the best out of light. PDK Grain, Nanaimo, Canada.
- Williams, P. y Norris, K. (1987). Qualitative applications of near-infrared reflectance spectroscopy. En P. Williams & K. Norris (Eds.), *Near-infrared technology in the agricultural and food industries* (pp. 241-246). St. Paul, MN: American Association of Cereal Chemists.
- Xie, L., Ying, Y. and Ying, T. (2009). Classification of tomatoes with different genotypes by visible and short-wave near-infrared spectroscopy with least-squares support vector machines and other chemometrics. *J. Food Eng.* 94, 1, 34–39.
- Zhang, H., Xu, F., Wu, Y., Hu, H., 3, Dai, X. (2017). Progress of potato staple food research and industry development in China. *Journal of Integrative Agriculture*, 16, 12, 2924–2932